



***Data mining* no âmbito da monitorização
não-intrusiva de cargas**

por

Ana Inês Soares Pinto Oliveira Soares

Tese de Mestrado em Análise de Dados e Sistemas de Apoio à
Decisão

Orientada por

Dr. João Gama
Dr. David Rua

Faculdade de Economia

Universidade do Porto

2016

Nota Biográfica

A autora desta dissertação de mestrado, Ana Inês Soares Pinto Oliveira Soares, nasceu a 26 de Agosto de 1993, em Viseu.

Licenciada em Economia pela Faculdade de Economia da Universidade de Coimbra em 2014.

Em 2014/16 frequentou o Mestrado de Modelação, Análise de Dados e Sistemas de Apoio à Decisão, na Faculdade de Economia da Universidade do Porto.

Agradecimentos

A realização desta tese de mestrado apesar de ser um trabalho individual contou com o importante apoio e ajuda de professores, familiares e amigos. Por isso gostava de agradecer:

- Ao Doutor João Gama, por me ter aceite como sua orientanda, pela orientação, pelo saber e pelas críticas construtivas;
- Ao Doutor David Rua, pela orientação, total disponibilidade, pelo saber, pelas críticas e pelas opiniões que ajudaram este trabalho a ir para frente e que sem elas não era possível a sua realização;
- Aos meus pais, à minha irmã, à minha avó e aos meus familiares, por todo o apoio e confiança que me transmitiram;
- Ao meu namorado por toda a paciência, compreensão, sabedoria e força que me transmitiu durante estes meses;
- Aos meus amigos por todo o apoio e compreensão, especialmente ao meu amigo André e à minha amiga Mariana;
- Aos meus parceiros do INESC que demonstraram compreensão e partilharam comigo diversas ideias que me ajudaram na elaboração deste trabalho.

Resumo

A tecnologia de informação e comunicação desempenha um papel importante na abordagem de problemas de energia em todo o mundo. As redes elétricas e os contadores inteligentes trazem uma mudança de paradigma para o setor de energia elétrica. Permitem uma monitorização da produção, distribuição e do consumo de energia. Podem ainda fornecer às famílias informações em tempo real sobre o seu consumo de eletricidade e, assim, ajudá-las a poupar energia. Porém, os contadores inteligentes ainda não conseguem fornecer informação detalhada sobre qual o dispositivo que se encontra ativado e quanto é que esse mesmo consumiu. Esta informação pode ser obtida com recurso a aparelhos que medem individualmente o consumo de cada dispositivo, através de uma monitorização intrusiva (o que é significativamente dispendioso), ou inferindo esta informação do consumo total de eletricidade medida por um medidor inteligente (métodos de monitorização não-intrusiva).

Ao longo deste trabalho são descritos três algoritmos de monitorização não intrusiva de cargas dos seguintes autores: Baranski and Voss (2004b), Weiss et al. (2012) e Parson et al. (2012). Todos eles apresentam métodos de inferência diferentes. O primeiro recorre a métodos não supervisionados (não é necessária nenhuma informação inicial), o segundo utiliza métodos supervisionados (requerem a utilização de dados pré-classificados) e por fim, o algoritmo de Parson et al. (2012), que emprega um método semi-supervisionado. Várias bases de dados e *frameworks* têm sido desenvolvidas para testar a performance de diversos algoritmos. O programa escolhido para a execução das experiências foi o NILM-Eval (, capaz de avaliar alguns algoritmos de monitorização não intrusiva de cargas. Selecionaram-se duas bases de dados para inferir o consumo de energia: o conjunto de dados ECO, que contem medições ao segundo de seis casas de famílias suíças (foi utilizado em todos os algoritmos) e o conjunto de dados REDD, onde estão registadas medições um pouco desfasadas de seis famílias norte americanas (apenas se usou no algoritmo de Parson). Quanto a esta última base de dados, foi necessário transformá-la de modo a ser utilizada no programa selecionado.

Palavras-Chave: Redes inteligentes, Contador inteligente, Monitorização não-intrusiva de cargas, Conjunto de dados, NILM-EVAL, ECO, REDD, Algoritmo

Abstract

Information and communication technology plays an important role in approaching energy issues throughout the world. Electrical networks and smart meters bring a paradigm shift for the electricity sector. They allow for monitoring the production, distribution and consumption of energy. They can also provide information in real time for families about their electricity consumption and thus help them save energy. However, the smart meters still cannot provide detailed information about which device is activated and how much it consumed. This information can be obtained from the use of devices that measure consumption of each device individually, through intrusive monitoring (which is highly expensive), or by inferring this information from the total electricity consumption measured by a smart meter (non-intrusive monitoring methods).

Throughout this work, three NILM algorithms (non-intrusive load monitoring algorithms) of the following authors are described: Baranski and Voss (2004b), Weiss et al. (2012) e Parson et al. (2012). They all feature different methods to infer the consumption of individual appliances. The first uses unsupervised methods (no initial information is required), the second uses supervised methods (they require the use of pre-classified data) and, finally, Parson et al. (2012) algorithm, which employs a semi-supervised method. Numerous databases and frameworks have been developed to test the performance of several algorithms. The program chosen for the develop of the experiments was the NILM-Eval, able to assess some non-intrusive load monitoring algorithms. Two databases were chosen to infer the energy consumption: the ECO data set, which contains measurements by second of six houses of Swiss families (this data was used in all algorithms) and the REDD data set provides data of six North American families, however, the data show measurements failures. As for this last database, it was necessary to transform it in order to be used in the selected program, this data set was used only for Parson et al. (2012) algorithm.

Keywords: Smart grids, Smart meter, Non-intrusive load monitoring(NILM), Data set, NILM-EVAL, ECO, REDD, Algorithm

Índice

Nota Biográfica	i
Resumo	iii
Abstract	iv
1 Introdução	1
1.1 Motivação	1
1.2 Objetivos	2
1.3 Organização	2
2 <i>Data mining</i> e monitorização não-intrusiva de cargas	3
2.1 Introdução	4
2.2 Aquisição de dados	5
2.3 Extração de características	6
2.3.1 Características em regime permanente	7
2.3.2 Características transitórias	9
2.4 Identificação de cargas	10
2.4.1 Técnicas supervisionadas	10
2.4.2 Técnicas não supervisionadas	12
2.5 Bases de dados	13
2.6 Métricas de avaliação	16
2.6.1 Métricas baseadas em eventos	16
2.6.2 Métricas que não se baseiam em eventos	17
2.7 Sumário do capítulo	18
3 Descrição dos algoritmos	19
3.1 Algoritmo de Baranski	19
3.1.1 Estrutura do Algoritmo	20
3.2 Algoritmo de Weiss	22
3.2.1 Estrutura do Algoritmo	22
3.3 Algoritmo de Parson	24

3.3.1	Estrutura do Algoritmo	24
3.4	Sumário	26
4	Metodologia de avaliação	27
4.1	NILM-Eval	27
4.2	Base de dados ECO	30
4.2.1	Residências	31
4.3	Base de dados REDD	32
4.4	Sumário	36
5	Resultados	38
5.1	Algoritmo de Baranski	39
5.2	Algoritmo de Weiss	40
5.3	Algoritmo de Parson	43
5.3.1	Experiência com o conjunto de dados REDD	45
5.3.2	Experiência com o conjunto de dados ECO	49
6	Conclusões	54
6.1	Trabalho Futuro	55
	Bibliografia	56
	Anexo	61
	A	61
	B	62
	C	65
	D	66
	E	67

Lista de Tabelas

2.1	Algoritmo de Hart (1992)	4
2.2	Tabela de comparação dos diversos tipos de bases de dados. Adaptado de http://blog.oliverparson.co.uk	15
2.3	Matriz de contingência	16
4.1	Informação sobre os dispositivos existentes em cada casa	31
4.2	Informação sobre os habitantes de cada casa	36
4.3	Categoria do dispositivos medidos em cada casa	37
5.1	<i>Clusters</i> obtidos para a casa 2	39
5.2	Máquina de estados finitos	40
5.3	Assinaturas obtidas para cada dispositivo da casa 2	43
5.4	Resultado das métricas na inferência do frigorífico recorrendo ao algoritmo de Weiss	44
5.5	Resultado das métricas da primeira casa	48
5.6	Resultado das métricas com treino no fim de semana	49
5.7	Resultado das métricas da segunda casa	50
5.8	Resultado das métricas com os dados ECO	53

Lista de Figuras

2.1	Sinal de consumo agregado, dados fornecidos pelo Instituto de Engenharia de Sistemas e Computadores, Tecnologia e Ciência (INESC) .	3
2.2	Estrutura das abordagens de desagregação de cargas	5
2.3	Classificação dos aparelhos	7
2.4	Características adicionais, Cole et al. (1998b) (<i>edges</i> e <i>slopes</i>)	8
2.5	Ilustração da delimitação transitória. Fonte: Figueiredo (2014)	9
2.6	Representação gráfica de uma rede neuronal artificial com duas camadas intermediárias	12
3.1	Estrutura do Algoritmo de Weiss	22
3.2	Estrutura do Algoritmo de Parson et al. (2012)	24
3.3	Modelo de Parson et al. (2012)	25
3.4	Fracção da potência agregada. Fonte: Parson et al. (2012)	26
4.1	Estrutura dos dados no NILM-EVAL	28
4.2	NILM-EVAL, fonte: Beckel (2015)	29
4.3	Consumo agregado do dia 01/06/2012 da primeira casa	30
4.4	Consumo dos dispositivos da casa nº1 em kWh por mês	33
4.5	Consumo dos dispositivos da casa nº2 em kWh por mês	33
4.6	Consumo dos dispositivos da casa nº3 em kWh por mês	34
4.7	Consumo dos dispositivos da casa nº4 em kWh por mês	34
4.8	Consumo dos dispositivos da casa nº5 em kWh por mês	35
4.9	Consumo dos dispositivos da casa nº6 em kWh por mês	35
5.1	Weiss - Consumo real e consumo inferido	41
5.2	Weiss - Detecção dos eventos ON e OFF do frigorífico no consumo agregado.	42
5.3	Weiss - Visualização do consumo inferido no consumo agregado.	44
5.4	Resultado da experiência com as médias do <i>tracebase</i> , consumo inferido (vermelho) e consumo da <i>plug</i> (verde)	46
5.5	Parson REDD casa 1 - Comparação entre o consumo inferido e o consumo real da experiência com uma janela de treino de 3 horas.	47

5.6	Parson REDD casa 1 - Comparação entre o consumo inferido e o consumo real da experiência com uma janela de treino de cinco horas.	47
5.7	Parson REDD casa 1 - Comparação entre o consumo inferido e o consumo real da experiência com um fim-de-semana como período de treino e teste.	49
5.8	Parson REDD casa 2 - Comparação entre o consumo inferido e o consumo real.	50
5.9	Parson eco experiência 1 - Comparação entre o consumo real e o consumo inferido, utilizando os dados sem nenhuma alteração.	51
5.10	Parson ECO experiência 2 - Comparação entre o consumo real e o consumo inferido, utilizando os dados do consumo total sem o consumo do congelador.	52
5.11	Parson ECO experiência 2 - Comparação entre o consumo inferido e o consumo total, utilizando os dados do consumo total sem o consumo do congelador.	52
5.12	Parson ECO experiência 3 - Comparação entre o consumo real e o consumo inferido, utilizando os dados do consumo total sem o consumo do congelador e com a aplicação de um filtro passa baixo.	53
A.1	Consumo elétrico do frigorífico na casa 1 (azul) e na casa 2 (vermelho) da base de dados REDD e o consumo do frigorífico da casa 2 (verde) da base de dados ECO	61
B.1	Parson REDD casa 1 - Comparação entre o consumo inferido e consumo agregado, da experiência com três janelas de treino.	62
B.2	Parson REDD casa 1 - Comparação entre o consumo real e consumo agregado, da experiência com três janelas de treino.	63
B.3	Parson REDD casa 1 - Comparação entre o consumo inferido e consumo agregado, da experiência com cinco janelas de treino.	63
B.4	Parson REDD casa 1 - Comparação entre o consumo real e consumo agregado, da experiência com cinco janelas de treino.	64
C.1	Parson ECO - Comparação entre o consumo inferido e o consumo total. Verifica-se que o comportamento durante a madrugada não apresenta um padrão que permita identificar o Frigorífico.	65
D.1	Parson ECO - Comparação entre o consumo do frigorífico e do congelador	66
E.1	Parson ECO experiência 3- Comparação entre o consumo do inferido e o consumo total.	67
E.2	Parson ECO experiência 3- Comparação entre o consumo real e o consumo total.	68

Lista de acrónimos

AMPds	Almanac of Minutely Power data set.
ECO	Electricity Consumption and Occupancy.
FN	False negative.
FP	False positive.
FPR	False positive rate.
FSM	Finite-state machine.
HES	Household Electricity Use Study.
Hmm	Hidden Markov model.
iAWE	Indian Dataset for Ambient Water and Energy.
kNN	k-Nearest Neighbors.
NILM	Non-intrusive load monitoring.
NILMTK	Non-intrusive load monitoring toolkit.
REDD	Reference Energy Disaggregation Data Set.
RMSE	Root-mean-square error.
SVM	Support vector machine.
TN	True negative.
TP	True positive.
TPR	True positive rate.
TV	Televisão.
UK-DALE	UK Domestic Appliance-Level Electricity.

Capítulo 1

Introdução

1.1 Motivação

As redes inteligentes que resultam da modernização das redes elétricas tradicionais têm vindo a criar oportunidades de implementação de serviços de energia onde o utilizador final poderá ter um papel de destaque na maneira como usa a energia elétrica. Para que seja possível caracterizar o uso de energia, nomeadamente o seu consumo, torna-se necessária a instalação de aparelhagem de medição de energia elétrica. Apesar de existirem já dispositivos que são utilizados para esse efeito, os vulgares contadores de eletricidade (que agora se vão tornando em contadores inteligentes, do anglo-saxónico *smart meters*), a verdade é que a informação disponibilizada ao utilizador é limitada e tem por base um único ponto de medida.

Embora se possam instalar equipamentos de medida em vários pontos de uma casa, com o intuito de caracterizar melhor o consumo de energia, essa abordagem tem custos associados. Como tal só em casos específicos é que se torna relevante o seu uso e noutros apenas em alguns dispositivos é que são considerados. Espera-se que no futuro o uso de dispositivos inteligentes (exemplo: eletrodomésticos inteligentes) possa permitir a medição discriminada de consumos. Contudo tal cenário demorará a concretizar-se pelo custo e pela longevidade que grande parte dos dispositivos atuais ainda tem.

Nesse sentido há que pensar em alternativas que permitam a recolha de informação

O uso de técnicas de desagregação pode ser considerado uma alternativa já que se propõem a estimar o consumo de cargas discriminadas tendo por base um único ponto de medição e recorrendo a mecanismos de aprendizagem automática que podem ser supervisionados, não-supervisionados ou mistos. Nesta tese consideram-se os algoritmos mais promissores do estado da arte e é feita a validação de alguns deles tendo por base um conjunto de premissas que se consideraram durante o trabalho associado à tese.

1.2 Objetivos

Este trabalho tem por objetivo o estudo de estratégias de desagregação de cargas, com particular ênfase às que privilegiem um único ponto de medição (consumo agregado). Para isso foi necessário:

- Conhecer as diferentes técnicas de *data mining* utilizadas na desagregação de cargas;
- Escolher algoritmos de desagregação e saber como atuam;
- Validar os mesmos com bases de dados públicas;
- Enumerar as vantagens e desvantagens dos algoritmos selecionados.

1.3 Organização

Este trabalho está estruturado em cinco capítulos sendo este primeiro a introdução, do segundo ao quinto o desenvolvimento e por fim a conclusão. No primeiro está brevemente descrita a motivação da realização desta tese, os principais objetivos e a sua estrutura. Nos seguintes é efetuada uma breve revisão de literatura relacionando o tema com as técnicas de *data mining*. No terceiro capítulo são descritos os três algoritmos selecionados para a utilização de monitorização-intrusiva de cargas. No quarto capítulo é descrito o programa e as bases de dados utilizadas. Após as descrições dos algoritmos, das bases de dados e do programa, segue-se o capítulo onde estão apresentados os resultados das experiências realizadas. Por fim, no último capítulo, são feitas conclusões acerca do trabalho e é sugerido trabalho futuro que poderá ser considerado tendo em conta o trabalho apresentado nesta tese.

Capítulo 2

Data mining e monitorização não-intrusiva de cargas

A Figura 2.1 representa um exemplo de consumo de eletricidade agregado, onde está incluída informação relativa ao uso de diversos dispositivos que foram utilizados num dado período de tempo. Sabemos que um ou mais aparelhos foram ativados sempre que se verifique um movimento ascendente no sinal e quando acontece o inverso estamos perante a desativação pelo menos um aparelho. Contudo, o gráfico não nos informa qual foi o dispositivo específico a ser ativado num dado momento. Assim sendo, recorrendo a métodos de monitorização não-intrusiva de cargas é possível estimar quando e quais terão sido os dispositivos que foram ativados e/ou desativados num dado intervalo de tempo.




Figura 2.1: Sinal de consumo agregado, dados fornecidos pelo Instituto de Engenharia de Sistemas e Computadores, Tecnologia e Ciência (INESC)

2.1 Introdução

A temática de desagregação de cargas, foi iniciada na década de 80, por Hart (1992), que desenvolveu o primeiro algoritmo no âmbito da desagregação de cargas. O algoritmo criado apresenta cinco etapas, mencionadas na Tabela 2.1, após a aquisição dos dados com frequência de 1 Hz e dos dados do sinal de potência¹ adquirido normalizado, através da utilização da equação:

$$P_{normalizada}(t) = \left[\frac{120}{v(t)} \right]^2 \times P(t). \quad (2.1)$$

Sendo que $v(t)$ é a tensão e $P(t)$ é a potência.

O algoritmo identifica as mudanças entre estados (mudança de um estado ON para OFF e vice-versa) através da análise aos dados normalizados. Na etapa seguinte, o algoritmo agrupa os eventos semelhantes num diagrama de assinaturas bidimensional onde um dos eixos é referente à potência ativa enquanto o outro eixo é relativo à potência reativa. Numa terceira etapa, a assinatura de cada dispositivo é definida através de dois grupos de eventos de igual magnitude e sinal oposto. Seguidamente, a cada evento é associada uma assinatura elétrica e por fim, o algoritmo classifica os aparelhos com base nos dados recolhidos.

Tabela 2.1: Algoritmo de Hart (1992)

Etapas	Descrição
1	Identificação das alterações no estado estacionário;
2	Localização das alterações num plano bidimensional;
3	São agrupados os <i>clusters</i> positivos e negativos com magnitude semelhante;
4	Resolução de todos os problemas de paridade que possam ter existido, para garantir que todos os eventos são associados ao seu par ou a um novo <i>cluster</i> ;
5	Associação dos pares de <i>clusters</i> a um consumo de uma carga conhecida de forma a determinar a contribuição de cada uma das cargas.

Contudo, este modelo apresenta algumas limitações como por exemplo, na identificação de aparelhos de apenas dois estados de funcionamento (serão falados mais

¹grandeza que determina a quantidade de energia consumida por uma carga a cada unidade de tempo

à frente), o modelo assume que a potência consumida pelos dispositivos quando ligados é idêntica à consumida no momento em que estes são desligados, o que pode pôr em causa a veracidade do mesmo, uma vez que alguns dispositivos sofrem variações ao longo do seu funcionamento.

Para ultrapassar estas limitações, diversos autores desenvolveram extensões a este trabalho, como por exemplo, a definição de um espaço de características tridimensional ou a consideração de características adicionais. A estrutura das abordagens é similar à representada na Figura 2.2. Existe uma fase de aquisição de dados, outra para extrair as características que definem a assinatura elétrica de um dispositivo e, por fim, a classificação das cargas para identificar o dispositivo.

Nas secções que se seguem é apresentada uma descrição detalhada sobre as três fases mencionadas anteriormente.

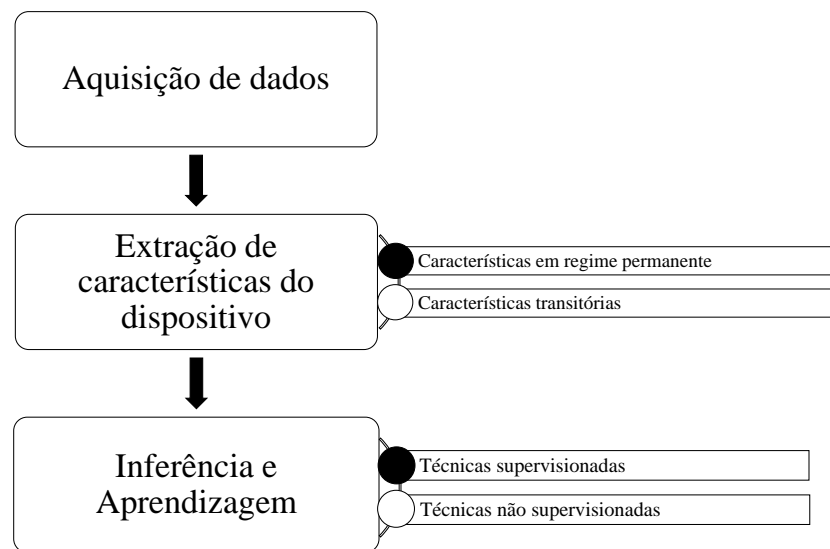


Figura 2.2: Estrutura das abordagens de desagregação de cargas

2.2 Aquisição de dados

Nesta secção é abordado o processo de aquisição de dados que é fundamental num sistema de monitorização não-intrusiva de cargas na definição de assinaturas elétricas. É considerado um processo fundamental porque é a partir dos dados que se

obtem as estimativas produzidas pelos algoritmos. Caso os dados não sejam consistentes podem induzir os algoritmos em erro, levando à obtenção de resultados indesejados. As medições podem ser efetuadas, por exemplo, através dos contadores das casas, de *smart meters*² ou *plugs*³.

A medição da tensão e corrente associada ao uso de um dispositivo permite extrair diferentes características, como por exemplo, a potência reativa⁴, potência ativa⁵, componentes harmônicas, etc. A eletricidade na Europa é entregue como corrente alternada a 50Hz (no caso dos EUA, e em muitas outras partes do mundo, é entregue a 60Hz), o que significa que o período das ondas sinusoidais é de $\frac{1}{50}$ segundos. Através do teorema de Nyquist-Shannon tornou-se possível a computação de maior parte das métricas tradicionais de energia. O teorema diz-nos que a taxa de amostragem⁶ de um sinal analógico deve ser maior ou igual a duas vezes a largura de banda desse sinal. O que significa que a taxa de amostragem do sinal analógico na Europa deve ser pelo menos de 100Hz.

As componentes harmônicas também podem ser uteis na identificação dos aparelhos e devem ser amostrados com uma taxa de 1.2kHz-2.0kHz. As características transitórias devem ser obtidas a uma taxa de amostragem de kHz ou até de MHz.

2.3 Extração de características

Após a extração dos dados brutos, segue-se o processamento e computação dos mesmos.

As assinaturas elétricas são a base de qualquer sistema de monitorização não-intrusiva. Estas são definidas, de acordo com o algoritmo de desagregação a utilizar, como um conjunto de características, que resultam de sinais em regime permanente ou de sinais transitórios, e que podem ser obtidas a partir da carga total.

Segundo Hart (1992), a definição de assinatura está relacionada com a natureza operacional de cada aparelho. Estes podem ser diferenciados em três categorias, ilustradas na figura 2.3:

1. Aparelhos On, são aparelhos com apenas dois estados de funcionamento, exemplo: uma torradeira e uma lâmpada;
2. Aparelhos de estado finito, são incluídos neste grupo os dispositivos com um número definido de estados, em que o seu ciclo de funcionamento é repetido

²É um dispositivo eletrónico que regista o consumo de energia elétrica em determinados intervalos e comunica essa informação, pelo menos diária de volta para o utilizador para a monitorização

³Fornecer dados sobre o consumo do dispositivo que se encontrar ativado à mesma.

⁴potência usada apenas para criar e manter os campos eletromagnéticos das cargas

⁵potência que realiza trabalho gerando calor, luz, movimento, etc.

⁶A amostragem de um sinal analógico é o processo pelo qual o sinal passa a ser representado por um conjunto discreto de números

frequentemente ao longo de um período de tempo, exemplo: máquinas de lavar a roupa e máquina de lavar loiça;

3. Aparelhos de consumo variável e estado não finito, dispositivos elétricos com um consumo variável ao longo do tempo e não possuem um padrão de funcionamento definido, exemplo: ferramentas elétricas.




Figura 2.3: Classificação dos aparelhos

Apesar de Hart (1992) ter definido apenas três categorias para os diferentes aparelhos elétricos, Zeifman and Roth (2011) e Baranski and Voss (2003) destacaram uma quarta categoria: aparelhos de consumo permanente, estes funcionam 24 horas por sete dias da semana, com uma potência reativa e ativa relativamente constante, exemplo: alarmes de incêndio.

2.3.1 Características em regime permanente

Uma assinatura em regime permanente ou estacionário é deduzida a partir da diferença entre os dois estados estacionários num sinal constituído por um conjunto de amostras consecutivas. Para cada um dos diferentes dispositivos é possível identificar três estados: um primeiro em que o sinal se encontra estável, antes de o interruptor do dispositivo ser ativado; um segundo estado estacionário que corresponde à fase de operação do aparelho e uma última fase estável que ocorre após o seu desligamento.

A abordagem de Hart (1992) procura mudanças na potência ativa e reativa. Porém, o algoritmo apenas reconhece corretamente os mecanismos com funcionamento *on/off*, apresentando dificuldades em identificar dispositivos de consumo finito e de consumo variável.

Cole et al. (1998b), focaram-se em descobrir características adicionais para identificar as cargas complexas, como são as máquinas de lavar louça ou os frigoríficos. Estes tipos de cargas consideram-se mais complexas no momento de ativação do que durante o seu funcionamento normal. Utilizando esta informação, os autores optaram por adicionar duas características ao seu processo de identificação: a utilização de *edges* (pico ascendente inicial de energia) e *slopes* (segundos seguintes ao pico), figura 2.4. Segundo estes, o nível de potência não é único durante o estado estacionário de uma carga, assim, este não é uma característica distintiva. Apenas

os picos iniciais e o comportamento nos segundos seguintes são únicos e permitem a distinção de cargas.




Figura 2.4: Características adicionais, Cole et al. (1998b) (*edges e slopes*)

Estudos seguintes, optaram por explorar assinaturas de estado estacionário usando apenas a potência ativa. Farinaccio and Zmeureanu (1999) e Marceau and Zmeureanu (2000) apresentam uma abordagem onde aplicam regras de decisão específicas para cada aparelho. Para a implementação das regras é necessário um período de treino, que deverá ser de uma semana, em que cada dispositivo é medido individualmente. Marceau and Zmeureanu (2000) melhoraram a abordagem anterior através da inclusão do pré-processamento que envolve a detecção de eventos *on/off*. O método desenvolvido por Baranski and Voss (2003), difere do anterior no facto de nenhum conhecimento ser necessário *à priori*.

Na abordagem Last-In-First-Out, proposta por Bijker et al. (2009), o algoritmo utilizado determina as mudanças de estados por ordem cronológica. Uma mudança positiva é guardada na memória e compensada por uma mudança negativa. Esta abordagem apresenta limitações similares às de Hart, (i) dificuldades em identificar dispositivos que não apresentem estados de ligar e desligar; (ii) falha na capacidade de distinguir aparelhos com consumos semelhantes.

A informação adicional fornecida pelas componentes harmónicas da corrente é útil para distinguir cargas que se sobrepõem nas potências ativas e reativas. A sua análise é realizada através do cálculo da transformada de Fourier ou do cálculo da transformada de wavelet. O trabalho realizado por Srinivasan et al. (2006), recorreu à transformada de Fourier para extrair a informação importante contida nas componentes das harmónicas. Esta informação é utilizada para treinar uma rede neuronal artificial e máquinas de vetores de suporte, baseados em modelos de

identificação de dispositivos.

2.3.2 Características transitórias

Verifica-se uma alteração entre dois *steady-states* quando se liga ou desliga um dado dispositivo e durante essa transição ocorrem modificações nos sinais elétricos que podem caracterizar um dispositivo, figura 2.5. As características extraídas da análise de sinais durante esta transição compõem a assinatura transitória do dispositivo. Ou seja, as assinaturas transitórias resultam do ruído no sinal elétrico causado pela comutação do estado desligado para o ligado, e vice-versa.




Figura 2.5: Ilustração da delimitação transitória. Fonte: Figueiredo (2014)

Estas assinaturas foram exploradas com a finalidade de as utilizar na identificação de cargas nos sectores comerciais e industriais. Contudo, este tipo de assinaturas, também pode ser utilizado na monitorização não intrusiva de cargas no sector residencial.

Patel et al. (2007) criou uma abordagem que faz uso do ruído elétrico produzido pela comutação dos aparelhos (ruído transitório) e durante o seu funcionamento (ruído contínuo). As características foram extraídas a partir deste sinal pelo algoritmo da transformada de Fourier e utilizadas como assinatura dos dispositivos. Este método necessita de uma fase de treino, onde as características de cada aparelho e suas combinações são aprendidas.

As assinaturas transitórias apresentam vantagens e desvantagens. Como principal vantagem permitem distinguir dois aparelhos diferentes, com um estado estacionário semelhante. A desvantagem prende-se no esforço que a análise da transição implica, o que pode tornar este tipo de assinatura, para uma solução de monitorização não intrusiva de carga no sector residencial, desinteressante.

2.4 Identificação de cargas

Após a extração das características a partir dos dados recolhidos é realizada a identificação das cargas associadas às mudanças no sinal agregado.

Para que a identificação dos dispositivos seja possível podem ser utilizados dois métodos: supervisionados, que requerem a utilização de dados pré-classificados, e não supervisionados, que não necessitam dessa informação. Grande parte dos trabalhos realizados em torno deste tema focam-se em técnicas supervisionadas, que requerem dados rotulados para treinar o classificador.

2.4.1 Técnicas supervisionadas

A maioria dos métodos de aprendizagem supervisionada adaptados para desagregação de cargas exploram grandes quantidades de dados à procura de padrões consistentes, recorrendo a técnicas de *data mining*. Existem diversas abordagens, como por exemplo, a utilização do algoritmo dos vizinhos mais próximos, árvores de decisão, classificador de Bayes, máquinas de vetores suporte e redes neuronais artificiais. O algoritmo dos vizinhos mais próximos é um método baseado em distâncias. É o algoritmo mais simples de todos de aprendizagem automática e é considerado como preguiçoso porque não aprende nenhum modelo compacto para os dados. Este classifica um novo objeto com base nos exemplos do conjunto de treino que são próximos desse objeto. Ou seja, primeiro o algoritmo memoriza os exemplos rotulados do conjunto de treino, para depois classificar uma classe desconhecida, recorrendo à distância entre o vetor de valores de atributos e cada exemplo rotulado em memória. Por exemplo, o algoritmo 5 – *NN* foi utilizado por Figueiredo et al. (2012) no seu trabalho.

As árvores de decisão são outro método de classificação. A estratégia deste método é dividir para conquistar. Uma árvore de decisão é construída de tal forma que cada nó contém um teste para um atributo e cada ramo descendente corresponde a um valor possível para esse atributo. Cada nó terminal ou folha representa uma classe de acordo com os ramos percorridos.

O classificador de Bayes também pode ser utilizado em problemas de desagregação do sinal. É um classificador probabilístico simples baseado na aplicação de teorema de Bayes. O modelo probabilístico determina o rótulo de uma carga A , recorrendo à probabilidade de A pertencer a uma classe B :

$$p(B|A) = \frac{p(B)p(A|B)}{p(A)} \quad (2.2)$$

Onde $p(A)$ é a probabilidade de uma carga, escolhida aleatoriamente, ser descrita pela classe A e $p(B)$ é probabilidade de uma carga, escolhida aleatoriamente, pertencer à classe B . Berges et al. (2009) utiliza este classificador recorrendo à distância Euclidiana entre os vetores e atinge noventa por cento de precisão.

As máquinas de vetores suporte desenvolvidas por Vapnik (1995), têm a capacidade de resolver problemas de classificação e regressão. Considerando um problema binário, o objetivo das máquinas é separar as instâncias das duas classes através de uma função que será obtida a partir dos exemplos conhecidos na fase de treino. O objetivo é produzir um classificador que funcione de forma adequada com exemplos que não foram aplicados durante o treino, adquirindo assim a capacidade de estimar as saídas de futuras novas entradas. Nas máquinas de vetores suporte lineares os dados de treino são linearmente separáveis (por um hiperplano) e um modelo linear pode ser usado. Seja X um conjunto de treino com n objetos $x_i \in X$ e seus respectivos rótulos $y_i \in Y$, em que X constitui o espaço de entrada e $Y = \{-1, +1\}$ são as possíveis classes.

$$h(x) = wx + b \quad (2.3)$$

Esta equação é utilizada para dividir o espaço de entrada X em duas regiões, $y_i = +1$ se $w \times x_i + b > 0$ e $y_i = -1$ se $w \times x_i + b < 0$. Em geral, há diversas combinações de valores de w e b capazes de separar corretamente os dados deste tipo de conjunto. Neste caso, existe, pelo menos, um hiperplano que define corretamente o modelo. As máquinas de vetor suporte procuram o hiperplano que terá a menor distância, ρ , entre a fronteira de decisão e qualquer um dos exemplos de formação. A margem é definida como a distância perpendicular entre o ponto mais próximo ρ do conjunto de dados e o hiperplano definido. Estes classificadores foram utilizados por Srinivasan et al. (2006), Figueiredo et al. (2012) e Lai et al. (2013).

As Redes Neurais Artificiais (RNAs) também têm sido utilizadas no contexto de desagregação energética. Foram inspiradas nos sistemas biológicos e como eles processam as informações. De um modo semelhante ao cérebro, uma RNA é uma estrutura de processamento densamente interligada cujos elementos chamados unidades (neurónios) determinam o comportamento da rede. A classificação de uma nova carga consiste em alimentar a rede com o vetor de características extraídas - a assinatura - via as unidades de entrada para a frente através das camadas ocultas. Nas camadas ocultas, as entradas são ponderadas, resumidas e transformadas por uma função de ativação, em cada camada, antes da transformação passar para próxima camada. A camada de saída determina a identificação da nova carga.

A técnica de aprendizagem mais popular é o algoritmo *backpropagation*. Este algoritmo apresenta duas etapas, uma fase para a frente e uma fase para trás. Na primeira, cada objeto de entrada é apresentado à rede para posteriormente ser recebido por cada um dos neurónios da camada intermediária da rede e se produzir um valor de saída, que é utilizado pelos neurónios da camada seguinte, como valor de entrada. Nesta última camada é produzido o valor final de saída que é comparado ao valor desejado para a saída desse neurónio. A diferença entre os dois valores de saída (o produzido e o desejado) indica o erro cometido pela rede para o objeto apresentado. Assim, este valor é utilizado na segunda fase (para trás), para ajustar




Figura 2.6: Representação gráfica de uma rede neuronal artificial com duas camadas intermediárias

os pesos de entrada. Este ajuste prossegue da camada de saída até a primeira camada intermediária.

2.4.2 Técnicas não supervisionadas

Os métodos de aprendizagem não supervisionada tentam alcançar a desagregação de carga sem a necessidade de um conhecimento prévio, sendo uma alternativa interessante para as abordagens anteriormente explicadas, que exigem conjuntos de dados de treino do modelo que não são práticos na sua recolha.

Goncalves et al. (2011) propõem uma abordagem não-supervisionada. Este método descreve os aparelhos em termos de mudanças graduais na potência ativa e reativa. Dado o sinal agregado, esses recursos são extraídos e os *clusters* são computados no plano. O procedimento de agrupamento deve determinar automaticamente o número de *clusters* que existem nos dados (que correspondem ao número de diferentes transições de estado) e o centróide destes *clusters* (correspondente à mudança de potência média para as transições). Foram investigados dois tipos de métodos de agrupamento: *Genetic k-Means* e *Hierarchical Agglomerative Clustering*. O primeiro método, é inicializado com o agrupamento aleatório de soluções que são avaliadas por meio de uma função de aptidão com base na distância euclidiana entre os pontos no mesmo *cluster*. O último visa construir uma hierarquia de grupos, onde cada observação inicialmente define seu próprio *cluster*, e em cada passo desta abordagem *bottom-up* os pares mais similares nos grupos são combinados. Os melhores resultados foram obtidos com *Genetic k-Means*.

Os modelos ocultos de Markov (sigla em inglês, HMMs) e as suas variantes também foram utilizadas para o problema da desagregação do sinal elétrico. Neste modelo probabilístico, as variáveis ocultas são consideradas os estados em que os

dispositivos se encontram (e que não são diretamente observáveis sendo apenas inferíveis pelas medições do seu consumo) e as variáveis observáveis correspondem ao consumo agregado da potência. O modelo procura a combinação de dispositivos que melhor descreve a observação. A abordagem escolhida por Parson et al. (2012) foi uma abordagem diferencial. Isto é, o modelo apresenta uma variável classificada como estado oculto, e duas variáveis observáveis: uma é o consumo agregado e a outra corresponde ao diferencial entre o consumo agregado no estado atual e no estado anterior. Este modelo será explicado, com detalhe, à frente.

2.5 Bases de dados

É essencial a utilização de dados reais quando se compara o desempenho de técnicas de monitorização não intrusiva de cargas. No entanto, tais conjuntos de dados são demorados e dispendiosos na sua obtenção. Para este fim, os investigadores começaram a divulgar publicamente os seus conjuntos de dados, contudo, estes variam consideravelmente tendo em conta os projetos de investigação.

A primeira base de dados disponibilizada para o tema em estudo foi *Reference Energy Disaggregation Data Set* (REDD) desenvolvida por Kolter and Johnson (2011a). A base de dados contém dados ao nível agregado bem como de cada dispositivo individual.

Desde então, outras bases de dados surgiram:

- *The Almanac of Minutely Power* (AMPds) ;
- BERDS Maasoumy et al. (2013);
- *The Building-Level fully-labeled data set for Electricity Disaggregation* (BLUED), Anderson et al. (2012);
- *Dutch Residential Energy Dataset* (DRED) Uttama Nambi et al. (2015);
- *Electricity Consumption and Occupancy data set* (ECO) Beckel et al. (2014);
- GREEND Monacchi et al. (2014);
- *The Household Electricity Use Study* (HES UK) Jean-Paul Zimmermann and Evans (Jean-Paul Zimmermann and Evans);
- *Indian Dataset for Ambient Water and Energy* (iAWE) Batra et al. (2014);
- *Individual Household Electric Power Consumption Data Set* (IHEPCDS) Lichman (2013);
- REFTT Murray et al. (2015);

- Smart Barker et al. (2012);
- Tracebase Reinhardt et al. (2012).

Seguidamente, na tabela 2.2 são enunciadas algumas propriedades dos diferentes conjuntos de dados que foram mencionados anteriormente.

Tabela 2.2: Tabela de comparação dos diversos tipos de bases de dados. Adaptado de <http://blog.oliverparson.co.uk>

Conjunto de dados	Instituição	Localização	Duração	Número de casas	Número de <i>plugs</i> por casa	Frequencia	Consumo Agregado	Termos de uso
AMPds	Simon Fraser U.	BC, Canadá	1 ano	1	19	1 min.	Sim	Registro
BERDS	U. California	Berkley	1 ano	N/A	4	20 seg.	Sim	Público
BLUED	CMU	PA, USA	8 dias	1	0	N/A	Não	Registro
DRED	TU Delft	Holanda	6 meses	1	12	N/A	Sim	Público
ECO	ETH Zurich	Suiça	8 meses	6	6-10	N/A	Sim	Público
GREEND	UNI Klagenfurt	Austria	1 ano	9	9	1 seg.	Sim	Público
HES UK	DECC	UK	3 meses	250	13-51	2 min.	Não	Academico
iAWE	IIIT-Delhi	Delhi	73 dias	33		1 seg.	Sim	Público
IHEPCDS	EDF RD	França	4 anos	1	3	1min	Sim	Público
REDD	MIT	MA, USA	3-19 dias	6	9-24	3 seg.	Sim	Registro
REFTT	University of Strathclyde	Glasgow	2 anos	20	9	8 seg.	Sim	Público
Smart	UMass	MA, USA	3 meses	1	54	1 seg.	Sim	Registro
Tracebase	Parmstadt	Alemanha	1883 dias	N/A	43	1 – 10 seg.	Sim	Público

2.6 Métricas de avaliação

As diversas abordagens relativas à monitorização não intrusiva de cargas apresentam métricas relacionadas com o desempenho dos seus métodos. Contudo, apesar de quase todas as publicações que abordam o tema apresentarem uma métrica diferente para avaliar o seu desempenho, nenhuma comparação pode ser feita uma vez que diferentes conjuntos de dados foram testados, como se pôde verificar no ponto anterior.

Esta secção discute as algumas das diversas métricas de precisão que têm sido utilizadas.

2.6.1 Métricas baseadas em eventos

As métricas baseadas em eventos, avaliam o grau de deteção de eventos, devido à alteração de estado do aparelho, de um algoritmo de desagregação (por exemplo, quando uma torradeira é ligada ou desligada).

O desempenho de um modelo de classificação binário (ON/OFF) é frequentemente avaliado pelas seguintes métricas: *accuracy*, *precision*, *recall*, *F-score*, e todas elas se baseiam numa matriz de contingência, representada na tabela 2.3 constituída por verdadeiros positivos (*True positive*, TP), falso negativos (*False negative*, FN), verdadeiros negativos (*True negative*, TN) e por falsos positivos (*False positive*, FP). TP designa o número de eventos classificados corretamente num dispositivo, TN indica o número de eventos classificados como não pertencente ao dispositivo, FP indica o número de eventos atribuídos erradamente a um dispositivo e os FN representam o número de eventos falhados pelo algoritmo.

Tabela 2.3: Matriz de contingência

		Resultado ON	Estimado OFF
Resultado Real	ON	TP	FN
	OFF	FP	TN

Accuracy é a percentagem de amostras positivas e negativas classificadas corretamente sobre a soma de amostras positivas e negativas.

$$accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (2.4)$$

Precision é a percentagem de amostras positivas classificadas corretamente sobre o total de amostras classificadas como positivas. Representa a proporção de tempo em que foi previsto o aparelho ser ativado e que foi realmente ligado.

$$precision = \frac{TP}{TP + FP} \quad (2.5)$$

Recall, também conhecido como true positive rate mede a proporção de amostras positivas classificadas corretamente. Ou seja, mostra a proporção de tempo em que o aparelho foi realmente ligado e que foi previsto estar ligado.

$$recall = \frac{TP}{TP + FN} \quad (2.6)$$

F-score pode ser interpretado como uma média ponderada entre a *precision* e *recall*, e atinge o seu melhor valor em 1 e pior em 0. Esta métrica tem sido usada por Berges et al. (2010) e Figueiredo et al. (2011) para comparar o desempenho de detecção de várias abordagens.

$$F-score = \frac{2 \times precision \times recall}{precision + recall} \quad (2.7)$$

2.6.2 Métricas que não se baseiam em eventos

Métricas que não se baseiam em eventos avaliam o grau de inferência do algoritmo em relação ao consumo de energia dos aparelhos individuais ao longo do tempo. Como tal, estas métricas são dependentes da taxa de amostragem dos dados de cada dispositivo.

Kolter and Jaakkola (2012) utilizaram a seguinte métrica:

$$\frac{\sum_{t=1}^T \sum_{n=1}^N \min \{y_t^{(n)}, \hat{y}_t^{(n)}\}}{\sum_{t=1}^T x_t} \quad (2.8)$$

onde $y_t^{(n)}$ é a procura real de energia, $\hat{y}_t^{(n)}$ é a procura estimada de energia do aparelho n num instante t e x_t é a procura de energia agregada num instante t .

Outra métrica também utilizada por diversos autores, como Parson (2011), foi a raiz do erro quadrático médio (RMSE, em inglês), que pode ser calculado para cada dispositivo. Esta métrica relaciona o erro no consumo estimado de potência em cada instante, em oposição ao erro na potência consumida ao longo de determinados intervalos de tempo.

$$RMSE = \sqrt{\frac{1}{T} \sum_{t=1}^T (y_t^{(n)} - \hat{y}_t^{(n)})^2} \quad (2.9)$$

A proporção do desvio do consumo de energia estimado do consumo de energia real ao longo de um período de tempo foi uma métrica utilizada por Beckel et al. (2014).

$$Dev = \frac{\left| \sum_{t=1}^T y_t^{(n)} - \sum_{t=1}^T \hat{y}_t^{(n)} \right|}{\sum_{t=1}^T y_t^{(n)}} \quad (2.10)$$

O erro normalizado, que é a soma da diferença entre a energia estimada e a energia real do aparelho n em cada intervalo de tempo t , normalizada pelos dispositivos de consumo total de energia, Batra et al. (2014).

$$Erro_N^7 = \frac{\sum_t |y_t^{(n)} - \hat{y}_t^{(n)}|}{\sum_t y_t^{(n)}} \quad (2.11)$$

2.7 Sumário do capítulo

Neste capítulo foi introduzido o problema da desagregação de energia recorrendo a métodos não intrusivos e foi efetuada uma revisão de literatura. Primeiro foi descrito o modelo original no âmbito do tema. Seguidamente descreveu-se a estrutura das abordagens que recorrem a métodos não intrusivos. As três partes que compõem esta estrutura são: a aquisição de dados, extração de características e a identificação das cargas. É essencial a utilização de dados reais para validar as técnicas de monitorização não intrusiva de cargas, como tal, neste capítulo é exposta uma tabela que faz um breve resumo sobre as bases de dados elaboradas no âmbito do tema em estudo. Também se encontram descritas, neste mesmo capítulo, as métricas de avaliação.

⁷erro normalizado

Capítulo 3

Descrição dos algoritmos

Nesta secção são descritos os algoritmos que serão avaliados mais à frente. Na tabela??, encontra-se um pequeno resumo com as principais características dos três algoritmos NILM implementados e avaliados nesta tese. Todos eles apresentam uma abordagem de aprendizagem diferente, um recorre a métodos supervisionados, outro a métodos não supervisionados, e por fim, outro recorre a um método híbrido, utilizando uma abordagem semi-supervisionada. É a este último que se irá dar preferência ao longo do trabalho, uma vez que o método utilizado necessita apenas de dados do consumo agregado e de um modelo geral do dispositivo. Este modelo permite encontrar ao longo do consumo agregado, períodos de tempo em que esse dispositivo se encontra ativado e retirar daí as características principais do dispositivo que permitirão a desagregação.

	Baranski	Weiss	Parson
Método	Deteção de Eventos <i>Clustering</i> dos eventos Algoritmo Genético Máquina de estados finitos Grafo direto Caminho mais curto	Normalização dos dados Deteção de <i>edges</i> Filtro mediana-media Extração do vetor delta Correspondência <i>Nearest neighbor</i>	Cadeias ocultas de Markov Modelo diferencial das cadeias Algoritmo de Viterbi
Input	Consumo agregado	Consumo agregado e assinaturas dos dispositivos	Consumo agregado e modelo geral do dispositivo
Output	Tabela de <i>clusters</i> e das máquinas de estados finitos	Tabela de assinaturas, métricas e gráficos	Gráficos e métricas
Desagregação	Todos os dispositivos	Todos os dispositivos ou dispositivos individuais	Dispositivos individuais

3.1 Algoritmo de Baranski

O algoritmo Baranski and Voss (2004b), pretende identificar padrões no consumo de energia elétrica agregada e atribui-los a aparelhos individuais. Primeiramente

são extraídos os eventos do consumo agregado que posteriormente serão agrupados segundo o critério de que eventos no mesmo *cluster* pertencem ao mesmo aparelho. Em seguida, é gerado um algoritmo genético para criar máquinas de estados finitos e determina qual o estado da sequência mais provável para cada um dos aparelhos.

3.1.1 Estrutura do Algoritmo

Seguidamente é explicada de forma detalhada a estrutura do algoritmo de Baranski and Voss (2004b).

1. O algoritmo inicia a detecção de eventos a partir da diferença entre a potência atual e a potência no instante de tempo anterior, através da seguinte equação:

$$\Delta P_{(t)} = P_{(t)} - P_{(t-1)} \quad (3.1)$$

onde $P_{(t)}$ é a potência atual e $P_{(t-1)}$ é a potência anterior. Após a identificação dos eventos, $(S_{(i)})$, estes são classificados segundo a seguinte regra:

$$\Delta P_{(t)} \in \begin{cases} S_{(i)} & \text{se } \Delta P_{(t)} > \delta \wedge \text{sgn}(\Delta P_{(t)}) = \text{sgn}(\Delta P_{(t-1)}) \\ S_{(i-1)} & \text{se } \Delta P_{(t)} > \delta \wedge \text{sgn}(\Delta P_{(t)}) \neq \text{sgn}(\Delta P_{(t-1)}) \end{cases} \quad (3.2)$$

onde δ , é um limite para eliminar os eventos mais pequenos, ou seja, o ruído.

2. Os eventos detetados anteriormente são agrupados, da seguinte forma: eventos com estruturas semelhantes são incluídos no mesmo *cluster*. O processo utilizado para agrupar os elementos foi o *fuzzy clustering* mais precisamente o algoritmo *fuzzy c means*. *Fuzzy c means* é um método de agrupamento (*clustering*) onde os elementos podem pertencer a mais do que um cluster e articulado a cada elemento está um nível de associação¹. O algoritmo baseia-se na minimização da seguinte função objetivo:

$$\sum_{i=1}^N \sum_{j=1}^C u_{ij}^{(m)} \|x_i - c_j\|^2 \quad (3.3)$$

Onde m é um número real maior do que 1, x_i é um elemento, c_j é o *cluster center*, e u_{ij} é o nível de associação de x_i no *cluster j*.

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad (3.4)$$

¹Força de associação entre o elemento e o cluster onde foi inserido

$$c_j = \frac{\sum_{i=1}^N u_{ij}^m \cdot x_i}{\sum_{i=1}^N u_{ij}^n} \quad (3.5)$$

Os passos para o método de agrupamento são os seguintes:

- Iniciar a matriz $U = [u_{ij}]$;
 - Calcular o vetores centro $C^{(k)} = [c_j]$ com a matriz $U^{(k)}$;
 - Atualizar a matriz $U^{(k)}$;
 - Se $\|U^{(k+1)} - U^{(k)}\| < \epsilon$ pára a iteração, caso contrário volta ao passo 2.
3. Depois de se obterem os *clusters* recorre-se a um algoritmo genético que cria uma matriz X, onde cada coluna corresponde ao cluster e cada linha corresponde ao dispositivo candidato. O objetivo do algoritmo genético é selecionar as melhores combinações de *clusters* que irão dar origem a várias máquinas de estados finitos (*Finite state machine, FSM*, literatura anglo-saxónica).
- Gera-se uma população formada por um conjunto aleatório de indivíduos (*clusters*) que podem ser vistos como possíveis soluções do problema;
 - A população é avaliada e para cada indivíduo é atribuída uma classificação que reflete a sua adequação a determinado ambiente (função *fitness*). São selecionados os indivíduos com melhor valor na função *fitness*. É possível comparar o processo de seleção com o processo de seleção natural de Darwin, onde os mais aptos são os escolhidos, enquanto os restantes são eliminados;
 - Os indivíduos escolhidos reproduzem-se através do *cross-over* ou de mutação para gerar descendentes para a próxima geração. No *cross-over* é escolhido inicialmente, um ponto aleatório, onde os indivíduos são divididos e suas partes são permutadas, gerando dois novos indivíduos. A mutação é necessária para a introdução e manutenção da diversidade genética da população, alterando arbitrariamente um ou mais componentes;
4. Após se obterem as combinações, cada linha da matriz X é utilizada para formar uma máquina de estados finitos. Ou seja, para cada linha constroem-se sequências de eventos das máquinas de estados finitos e calcula-se a duração média de todas as sequências de eventos que têm uma probabilidade elevada de pertencer ao caminho mais curto. Seguidamente constrói-se um grafo orientado com as sequências de eventos como 'nós' e calcula-se o caminho mais curto. Este processo é repetido por todas as linhas da matriz;

5. Por fim, resolvem-se possíveis conflitos que possam existir (eventos atribuídos a mais do que uma máquina de estados finitos).

3.2 Algoritmo de Weiss

O algoritmo de Weiss et al. (2012) extrai eventos do consumo de eletricidade total e atribui a cada evento o aparelho com a melhor correspondência entre a base de dados e as assinaturas. Este algoritmo baseia-se na abordagem desenvolvida por Hart (1992), que agrupa os eventos numa fase de treino e atribui cada evento ao aparelho com o melhor conjunto de correspondência durante a operação. O número de grupos é determinado de forma dinâmica. Em contraste com Hart (1992), o algoritmo de Weiss et al. (2012) baseia-se em dados de consumo de três dimensões (potência ativa, potência reativa e potência de distorção) e suaviza o sinal antes de extrair eventos.

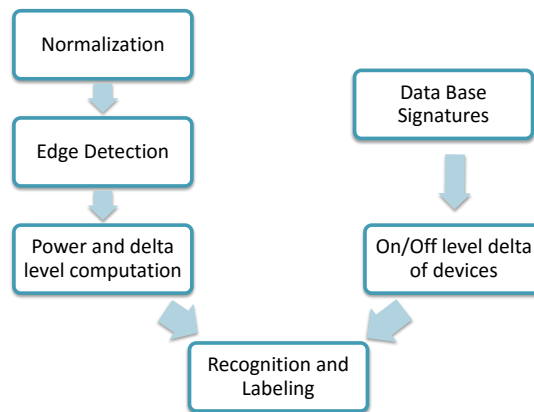


Figura 3.1: Estrutura do Algoritmo de Weiss

3.2.1 Estrutura do Algoritmo

A estrutura do algoritmo é formada por seis passos enunciados na figura 3.1.

1. Primeiro é necessário normalizar os dados, uma vez que, variações na tensão podem induzir varias diferenças no consumo de potência, por isso existe a ne-

cessidade de normalizar a potência numa tensão constante (potência aparente normalizada);

2. Seguidamente, utilizando a potência aparente normalizada como entrada, o algoritmo detecta eventos calculando os valores absolutos das diferenças entre dois valores consecutivos de potência. Se um valor absoluto dessa diferença é maior do que um limiar predefinido então esse valor pertence a um *edge*. Porém, podem ocorrer erros na detecção dos *edges*, devido ao ruído existente no sinal. Com objetivo de remover falsos eventos, Weiss et al. (2012) testaram diversos filtros dos quais o que obteve melhores resultados foi o filtro de *kernel*. Contudo, como o filtro implicaria custos computacionais demasiado elevados, os autores optaram por utilizar uma combinação de filtro de mediana, que remove os outliers, com um filtro de media, que suaviza o sinal;
3. Após a identificação dos *edges* e a eliminação do ruído (sinal suavizado) o passo seguinte é a extração dos níveis de potencia que conectam dois *edges*. Com os níveis de potencia obtidos o algoritmo extrai o vetor delta (diferença entre dois níveis de potencia) que é utilizado para a correspondência do *edge* a um dispositivo;
4. Seguidamente vem o reconhecimento, onde algoritmo tenta corresponder as assinaturas conhecidas com os vetores delta obtidos no passo anterior. O algoritmo calcula para cada delta (\vec{d}_i) a distância euclidiana até cada assinatura (\vec{k}_j) e se:

$$\left\| \vec{d}_i - \vec{k}_j \right\| < r \times \left\| \vec{k}_j \right\| + osc \begin{cases} \text{se } \mathbf{verdadeiro}, \vec{k}_j \text{ é uma potencial correspondência} \\ \text{para} \\ \text{se } \mathbf{falso}, \vec{k}_j \text{ não é uma potencial correspondência} \\ \text{para} \end{cases} \quad (3.6)$$

o termo de oscilação (*osc*) é o comprimento de um vetor que consiste no desvio padrão máximo da potência ativa no nível i ou $i+1$ como primeira componente, e o desvio padrão máximo da potência reativa no nível i ou $i+1$ como segunda componente.

5. Após cada delta ter uma serie de assinaturas candidatas, para cada uma destas assinaturas é utilizado o método *nearest neighbor*, com o objetivo de associar uma assinatura a um delta;
6. Por fim o algoritmo armazena em tabela todas as correspondências.

3.3 Algoritmo de Parson

O algoritmo de Parson et al. (2012) baseia-se nos modelos ocultos de Markov (*HMMs*, descrição anglo-saxónica) e no algoritmo Viterbi para desagregar o consumo de eletricidade. É considerada uma abordagem semi-supervisionada porque inicialmente é definido um modelo geral do dispositivo que se pretende desagregar, que posteriormente (numa fase de treino) é ajustado com recurso às assinaturas extraídas da carga agregada. Estas são utilizadas na desagregação, com recurso ao algoritmo de Viterbi. Após se obter a inferência da carga, esta é retirada ao sinal agregado. Consequentemente emergem outros padrões sobre os quais se repete o processo até se extraírem todas as cargas.

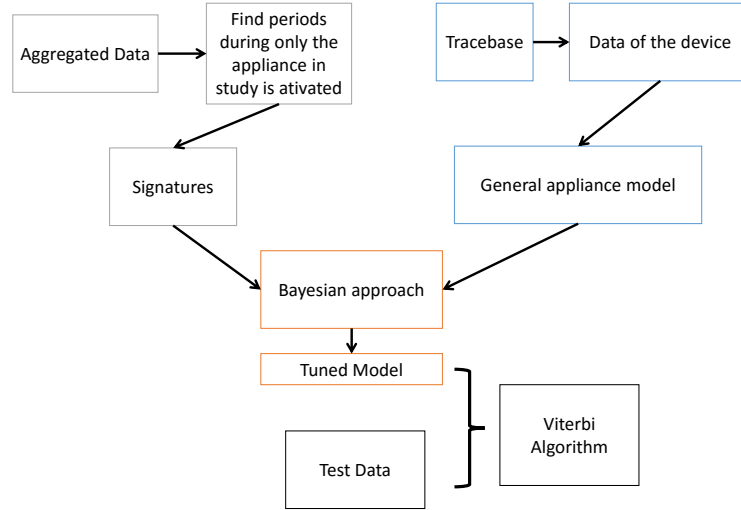


Figura 3.2: Estrutura do Algoritmo de Parson et al. (2012)

3.3.1 Estrutura do Algoritmo

Parson et al. (2012) modela cada dispositivo como uma HMM. Na figura 3.3 encontra-se representado o modelo de um dispositivo onde cada variável discreta, z_t , na cadeia de Markov representa o estado do aparelho num dado instante e assume um valor inteiro no intervalo $[1; K]$, onde K é o número de estados. Este modelo difere das HMM originais, uma vez que são consideradas duas observações x e y . A sequência x representa o consumo agregado da casa. A sequência y representa a diferença na potência total entre intervalos de tempo consecutivos, ou seja, é dependente do estado do aparelho no intervalo de tempo atual e no anterior.

Cada HMM é definida por três parâmetros: pela probabilidade do estado inicial, pela probabilidade de transição de estado e pela probabilidade de uma observação ser

gerada pelo estado de um dispositivo. Os autores utilizaram a base de dados *Trace-base* para realizar uma estimação inicial que mais tarde é complementada/corrigida com o treino. Esta base de dados foi criada por um grupo da Universidade de Darmstadt, e contém dados individuais de diversos dispositivos. Com os dados fornecidos por esta base de dados estes dados é possível estimar os parâmetros para cada tipo de dispositivo, recorrendo para isso a uma abordagem bayesiana, neste caso no Matlab é utilizada a *Bayes Net Toolbox*. No final do processo é obtido um modelo geral para cada tipo de dispositivo (por exemplo: um modelo que defina todos os frigoríficos) que será utilizado no processo de treino.




Figura 3.3: Modelo de Parson et al. (2012)

Fase de treino

Nesta fase de treino, pretende-se identificar períodos dentro do consumo agregado do *ECO dataset*, onde um único aparelho se encontra a mudar de estado e utilizá-los para melhorar o modelo geral pré-definido. O algoritmo EM permite que isto aconteça. Com os parâmetros iniciais, que definem o modelo inicial do dispositivo (médias, variâncias), inicia-se o passo E (*expectation*), onde uma distribuição de probabilidade, tipicamente normal, sobre a carga é definida, ou seja, com os parâmetros iniciais são calculadas probabilidades do comportamento detetado no consumo agregado pertencer ao dispositivo. Seguidamente, são estimados novos parâmetros baseados nas probabilidades de distribuição encontradas no passo anterior (passo M, *maximization*). Este processo repete-se até convergir. Observado na figura 3.4 o período de tempo entre meia noite e as seis da manhã, onde a performance do frigorífico é evidente, conclui-se que a fração da potência total exemplifica um possível período de treino para o dispositivo.

Desagregação

Para determinar a sequência ótima de estados de uma cadeia de Markov, dada uma sequência de observações foi utilizado o algoritmo de Viterbi. É um algoritmo de programação dinâmica para encontrar a sequência mais provável de estados ocultos tendo em conta os eventos observados.




Figura 3.4: Fracção da potência agregada. Fonte: Parson et al. (2012)

3.4 Sumário

Neste capítulo foram descritos três algoritmos distintos. O primeiro a ser explicado foi o algoritmo Baranski and Voss (2004b) que pretende identificar padrões no consumo de energia elétrica agregada, através de métodos de agrupamento e atribuí-los a aparelhos individuais, recorrendo a máquinas de estados finitos de modo a determinar qual a sequência mais provável para cada um dos aparelhos. Segue-se a abordagem de Weiss et al. (2012), onde eventos do consumo de eletricidade total são extraídos e atribui-se a cada evento o aparelho com a melhor correspondência entre a base de dados e as assinaturas. Por fim, o algoritmo de Parson et al. (2012) que se baseia nos modelos ocultos de Markov e no algoritmo Viterbi para desagregar o consumo de eletricidade.

Capítulo 4

Metodologia de avaliação

Na primeira parte deste capítulo explicamos o NILM-Eval, *framework open source* criado por Beckel et al. (2014). Encontra-se em MATLAB (NILM-Eval) e foi utilizado na avaliação dos três algoritmos de monitorização não intrusiva de cargas escolhidos. Seguidamente, são descritas as bases de dados utilizadas para realizar a validação dos algoritmos. A primeira base de dados a ser descrita é a base de dados suíça *Electricity Consumption and Occupancy* (ECO) criada pelo autor do *framework*. O segundo conjunto de dados que é considerado é americano e já foi utilizado por Kolter and Johnson (2011b), *Reference Energy Disaggregation Data Set* (REDD).

4.1 NILM-Eval

NILM-Eval é um *framework open source* em MATLAB, que capaz de avaliar alguns algoritmos de monitorização não intrusiva de cargas. Permite repetir experiências já realizadas por outros investigadores, avaliar alguns algoritmos com diferentes conjuntos de dados, e ajustar as configurações para melhorar o desempenho do algoritmo. Os algoritmos existentes neste *framework* são: o de Baranski, o de Weiss e o de Parson. Também é possível criar o próprio algoritmo, uma vez que, o autor disponibiliza um documento onde explica como o elaborar. Possibilita ainda a utilização de diferentes conjuntos de dados desde que sigam a estrutura representada na figura 4.1. É necessário criar primeiramente uma pasta com o nome da base de dados (no esquema o nome dado foi 'Data'). Após este passo, criam-se mais duas pastas: uma referente ao consumo medido pelo *smartmeter* e outra referente ao consumo de cada *plug*. Na pasta do consumo do *smartmeter* os dados necessitam de estar divididos em diferentes pastas, tendo em conta a casa a que se referem, e encontram-se divididos em ficheiros com dados diários. Na outra pasta, os dados para além de se encontrarem divididos por casa, também são divididos por dispositivo.

Na figura 4.2 esta representado o esquema geral do funcionamento deste *fra-*

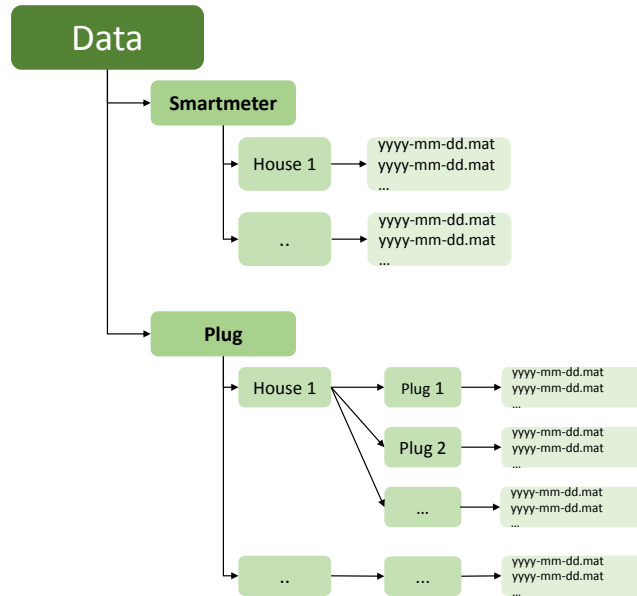


Figura 4.1: Estrutura dos dados no NILM-EVAL

mework. Inicialmente, é necessário escolher qual o algoritmo que se pretende utilizar. Seguidamente o utilizador tem de especificar as configurações padrão onde se encontram os parâmetros para avaliar o algoritmo e adaptá-lo ao conjunto de dados (no capítulo seguinte serão enunciadas as especificações de cada um). Após estes passos, é possível criar diversas experiências consoante as configurações padrão definidas que serão posteriormente utilizadas. Para cada uma das experiências o NILM-Eval cria um ficheiro *setup* que serve de entrada para o arranque da avaliação.

No final, o programa fornece como resultado:

- o valor de cada um dos indicadores de desempenho suportados pelo algoritmo;
- a estimativa de consumo de cada aparelho ou dos eventos;
- uma série de parcelas que ilustram os resultados, tendo em conta o output de cada algoritmo.

Para avaliar o desempenho de um algoritmo, NILM-Eval suporta várias métricas como a raiz do erro quadrático médio (RMSE), o desvio entre o consumo de energia estimado e o consumo de energia real ao longo de um período de tempo (Dev), *accuracy*, *precision*, *recall*, *F-score*. Estas quatro ultimas métricas baseiam-se

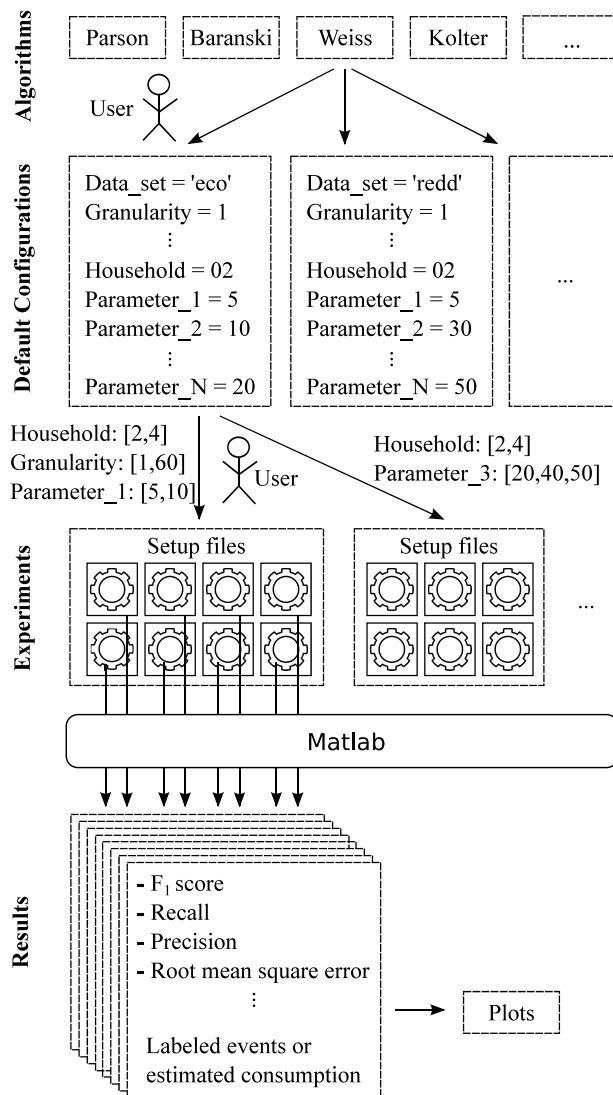


Figura 4.2: NILM-EVAL, fonte: Beckel (2015)

numa matriz de contingência, constituída por verdadeiros positivos (*True positive*, TP), falso negativos (*False negative*, FN) e por falsos positivos (*False positive*, FP).

Um outro *framework open source* que existe é o NILMTK publicado por Batra et al. (2014). É um kit de código aberto projetado especificamente para permitir a comparação de algoritmos de desagregação de energia, projetado para ajudar os investigadores a avaliar a precisão dos algoritmos na área da monitorização não intrusiva de cargas. Fornece funções que são úteis na conceção e implementação de algoritmos, é baseado em *Python*, suporta vários conjuntos de dados e

contém implementações de vários algoritmos, como o algoritmo de Hart (1992). Entre outras ferramentas, este programa disponibiliza um conjunto de algoritmos de pré-processamento, estatísticas para descrever conjuntos de dados, algoritmos de desagregação, métricas de precisão. Este *framework open source* não foi utilizado para realizar experiências, optou-se por utilizar o *framework open source* NILM-EVAL, uma vez que foi de fácil compreensão e não apresentou grandes entraves na sua utilização.

4.2 Base de dados ECO

O conjunto de dados ECO ¹ encontra-se disponível on-line, e pode ser utilizado no âmbito da monitorização de cargas recorrendo a uma metodologia não-intrusiva. Os dados foram recolhidos em seis casas de famílias suíças durante um período de oito meses (desde junho de 2012 a Janeiro de 2013). Para cada uma das casas, o conjunto de dados fornece:

- Dados de consumo agregado a 1 Hz;
- Dados individuais de cada dispositivo a 1 Hz, obtidos através das *plugs*, que foram colocadas em cada casa;
- Informações sobre a ocupação em cada habitação.




Figura 4.3: Consumo agregado do dia 01/06/2012 da primeira casa

¹Estes dados foram obtidos para o projeto *Smart Meter Services* que se encontra relacionado com o *framework NILM-Eval*

No total, existem mais de 100 milhões de medições, onde cada uma das medições contém informações sobre a tensão, a corrente e mudança de fase entre tensão e corrente.

4.2.1 Residências

As seis residências utilizadas na elaboração da base de dados apresentam alguns aparelhos em comum, como é possível observar na tabela 4.1, os dispositivos que aparecem com maior frequência são: o frigorífico, o fervedor, o congelador e a máquina de café.

Tabela 4.1: Informação sobre os dispositivos existentes em cada casa

Dispositivo	casa
Frigorífico	1,2,3,4,5,6
Fervedor	1,2,3,5,6
Congelador	1,2,3,4
Máquina de café	1,3,5,6
Tablet	2,3,4,5
TV + Stereo	3,4,5,6
Iluminação	2,4,6
Laptop	2,6
Computador + Router	1,5
Microondas	4,5
Máquina de secar roupa	1
Máquina de lavar roupa	1
Máquina de lavar loiça	2
Fogão	2
TV	2
Aparelhagem Audio	2
Stereo + Laptop	4
Computador	3
Router	6
Dispositivos da cozinha	4
Fonte	5

Seguidamente são demonstradas figuras referentes ao consumo de eletricidade captado pelas *plugs*, para cada uma das seis casas². Na primeira casa apenas sete

²cada um dos valores representa *kWh* por mês consumidos pelo aparelho

dispositivos é que se encontravam com *plugs*, o gráfico mostra uma porção significativa de uma secção denominada por outros que é medido pelo *smartmeter*, mas não é atribuída a um aparelho. Este facto é aplicável a todas as casas. A segunda casa é a que apresenta o maior número de medições individuais de dispositivos, cerca de 80% do consumo de eletricidade é medida pelas *plugs*. Os 20% restantes provavelmente, dizem respeito à iluminação e aos aparelhos móveis, tais como o aspirador. Na recolha de dados da terceira casa ocorreu uma falha na comunicação entre o *gateway* e as *plugs*. Por esta razão é preferível omitir os dados recolhidos nesta habitação e concentrar o estudo das restantes cinco casas. Em relação à quarta casa, a repartição do consumo mostra que o congelador consome quase um quarto do consumo de eletricidade do agregado familiar, consome 130 *kWh*, o que é cerca de dez vezes mais do que os congeladores nas outras casas consomem. Na quinta casa, a percentagem é maior no sector "outros" uma vez que, a família utiliza na sua casa uma bomba para a fonte situada no seu jardim que não é medida por nenhuma *plug* e consome 300 *W* durante o dia. Por fim na casa numero 6 observa-se que dos dispositivos medidos com *plug* o conjunto que apresenta maior consumo é a televisão com stereo.

Para além dos dados sobre o consumo agregado e individual dos dispositivos, também foi referido que esta base de dados disponibilizava dados para o monitoramento da ocupação, para a deteção da ocupação ou não de uma dada habitação ou de um compartimento da mesma. Este tipo de informação encontra-se discriminada na tabela 4.2. A análise deste tipo de situações é importante, por exemplo, para um sistema de ar condicionado automático, onde sabendo quando é que um dado compartimento ou mesmo a própria casa se encontra ocupada é possível regular a temperatura interna. Estes dados foram medidos através de um computador tablet e de um sensor infravermelho passivo (em algumas das famílias).

4.3 Base de dados REDD

REDD é uma base de dados Americana que contém dados do consumo de energia agregada (medidos de segundo a segundo) e dados do circuito individual da casa, ou seja, registo de funcionamento de cada dispositivo. Existem entre 9 e 24 aparelhos com medições de 3 em 3 ou 4 em 4 segundos. Existe informação sobre 6 casas de famílias norte-americanas. Ainda se encontra disponíveis dados sobre a corrente de alta frequência/tensão. O acesso aos dados encontra-se protegido por senha para manter o controlo de seu uso, contudo enviando um correio eletrónico será cedida a palavra-chave. REDD é até à data o conjunto de dados mais utilizados (e citada) para a monitorização não intrusiva, mesmo com um número relativamente curto de dados recolhidos (sensivelmente, 19 dias). A tabela 4.3 descreve a categoria de cada dispositivo medido em cada casa.




Figura 4.4: Consumo dos dispositivos da casa n°1 em kWh por mês




Figura 4.5: Consumo dos dispositivos da casa n°2 em kWh por mês




Figura 4.6: Consumo dos dispositivos da casa n°3 em kWh por mês




Figura 4.7: Consumo dos dispositivos da casa n°4 em kWh por mês




Figura 4.8: Consumo dos dispositivos da casa n°5 em kWh por mês




Figura 4.9: Consumo dos dispositivos da casa n°6 em kWh por mês

Tabela 4.2: Informação sobre os habitantes de cada casa

Residência	Tipo de residência	Ocupantes
1	Moradia	Trabalhador full-time (33 anos), Dona de casa (33 anos), Filho (3 anos) e Filho (1 ano)
2	Apartamento	Trabalhador full-time (34 anos) e Trabalhador part-time (32 anos)
3	Moradia	Trabalhador full-time (40 anos) e Dona de casa (40 anos)
4	Moradia	Trabalhador full-time (55 anos), Dona de casa (33 anos), Filho (17 anos) e Filho (15 anos)
5	Moradia	Trabalhador full-time (62 anos), Dona de casa (64 anos)
6	Moradia	Duas pessoas

4.4 Sumário

Neste capítulo foram descritas as bases de dados e o *framework open source*, que vão ser utilizados no capítulo seguinte, onde serão efetuadas diversas experiências. O conjunto de dados ECO será aplicado nos três algoritmos, enquanto o REDD será apenas utilizado num único algoritmo.

Tabela 4.3: Categoria do dispositivos medidos em cada casa

Casa	Categoria de dispositivos com <i>plug</i>
Casa 1	2 contadores, 2 fornos, 1 frigorífico, 1 máquina de lavar loiça, 4 canais de cozinha, 3 iluminação, 3 máquinas de lavar e secar roupa, 1 micro-ondas, 1 casa de banho, 1 fervedor, 1 fogão
Casa 2	2 contadores, 1 frigorífico, 1 máquina de lavar loiça, 2 canais de cozinha, 1 iluminação, 1 máquinas de lavar e secar roupa, 1 micro-ondas, 1 fogão, 1 dispensa
Casa 3	2 contadores, 3 canais do exterior, 1 frigorífico, 1 máquina de lavar loiça, 2 canais de cozinha, 5 iluminação, 2 máquinas de lavar e secar roupa, 1 micro-ondas, 1 forno, 1 dispensa, 1 casa de banho, 1 alarme de fumo
Casa 4	2 contadores, 1 canais do exterior, 1 máquina de lavar loiça, 1 canais de cozinha, 1 fogão, 4 iluminação, 1 máquinas de lavar e secar roupa, 3 ar-condicionado, 1 alarme de fumo, forno, 2 casa de banho, 1 diversos
Casa 5	2 contadores, 1 micro-ondas, 5 iluminação, 4 canais do exterior, 2 canais de cozinha, 2 fervedores, 1 forno, 2 máquinas de lavar e secar roupa, 1 casa de banho, 1 frigorífico, 1 máquina de lavar loiça, 1 dispensa, 2 subpaineis
Casa 6	2 contadores, 2 canais de cozinha, 1 máquinas de lavar e secar roupa, 1 fogão, 1 casa de banho, 1 frigorífico, 1 máquina de lavar loiça, 2 canais do exterior, 1 fervedores, 1 iluminação, 3 ar-condicionado

Capítulo 5

Resultados

Neste capítulo tem-se como objetivo principal validar os algoritmos e analisar o seu desempenho. O algoritmo ao qual se dá maior ênfase neste trabalho é o algoritmo de Parson. A importância dada a este algoritmo prende-se no facto de este apresentar uma teoria bastante inovadora, diferentemente das abordagens existentes. O seu modelo não requer dados de treino recolhidos pelas *plugs*, nem assume conhecimento completo dos dispositivos presentes na casa em estudos. Em vez disso, deparamo-nos com uma abordagem em que é definido um modelo geral dos dispositivos que posteriormente são ajustados com recurso a assinaturas extraídas da carga agregada, onde apenas o dispositivo em questão se encontra ativado. Os dispositivos são assim, separados iterativamente do consumo agregado.

A primeira parte da apresentação de resultados é relativa ao modelo de Baranski, que não recorre a qualquer tipo de informação prévia. Através da sua validação com recurso ao conjunto de dados ECO, pretendemos saber como é que comporta um algoritmo quando não apresenta nenhuma informação a priori. A segunda parte do capítulo de resultados diz respeito ao modelo criado por Weiss. Neste caso existe um conhecimento inicial sobre a carga. Também se recorreu à mesma base de dados da experiência anterior. Por fim, é avaliado o algoritmo ao qual se dá maior ênfase neste trabalho. Dado que é o algoritmo com especial preferência, este é testado com dois conjuntos de dados distintos, um europeu, ECO e outro americano, REDD. Também são testados cenários diferentes, para averiguar qual é o comportamento do algoritmo em diferentes circunstâncias e com bases de dados diferentes. Cada experiência é assente num cenário específico que se define num conjunto de ficheiros de configuração, tendo em conta cada algoritmo, conjunto de dados e o dispositivo em questão.

5.1 Algoritmo de Baranski

Este algoritmo é não supervisionado, ou seja, a desagregação das cargas é efetuada sem se recorrer a nenhum o conhecimento prévio dos dispositivos. Para a realização da experiência é necessária a definição de determinadas configurações como quantas vezes se repete a inferência em intervalos de treino diferentes, qual a granularidade escolhida (em segundos), o conjunto de dados para a validação, casa ou conjuntos de casas, o número de agrupamentos (*clusters*), número de máquinas de estado finito, número máximo de estados de uma máquina de estado finito e o número de dias escolhido para a avaliação.

No ensaio realizado para testar o algoritmo recorreu-se ao conjunto de dados ECO, utilizando a casa número 2, uma vez que é a que apresenta o maior número de dispositivos. Para este algoritmo não se define qual o dispositivo que se quer desagregar, uma vez que ele analisa todos os dispositivos e agrupa-os consoante as suas parecenças. Foram escolhidos 10 *clusters*, ou seja, os dispositivos serão agrupados em 10 grupos diferentes e o número de máquinas de estado finito escolhido foi 5, cada uma com um máximo de estados igual a 2.

A tabela 5.1 faz referência aos agrupamentos obtidos. Na primeira coluna encontram-se enumerados os *clusters*, a seguinte representa a permuta no consumo de eletricidade (aumento ou diminuição) onde estão inseridos eventos têm isso em comum. A terceira coluna demonstra o número de eventos associados ao *cluster*. As colunas 'Dispositivo 1' e 'Dispositivo 2' classificam o primeiro e segundo dispositivo que apresenta o maior número de eventos associado ao *cluster*. As duas colunas que têm o símbolo '%' representam a proporção de eventos associados a cada dispositivo.

Tabela 5.1: *Clusters* obtidos para a casa 2

<i>Cluster</i>	Δ Potência (W)	Tamanho do <i>cluster</i>	Dispositivo 1	%	Dispositivo 2	%
1	-12	7079	Laptop	34	Frigorífico	3
2	13	6827	Laptop	36	Frigorífico	4
3	-68	3116	Congelador	41	Frigorífico	28
4	85	2961	Congelador	37	Frigorífico	6
5	1128	341	Fogão	11	Frigorífico	6
6	-1097	323	Fogão	15	Frigorífico	8
7	-1855	210	Fogão	20	Fervedor	12
8	1860	210	Fogão	19	Fervedor	12
9	2447	189	Fogão	16	Laptop	4
10	-2438	183	Fogão	21	Máquina de lavar loiça	3

Com base na tabela 5.1, o algoritmo gera a máquina de estados finitos (FSM)

representada na tabela 5.2. A segunda e terceira coluna indicam as mudanças de potência nos centróides dos *clusters*. As duas últimas colunas representam os dispositivos que mais se adequam às mudanças de potência. O fogão é o dispositivo que aparece em mais máquinas de estados finitos. Na FSM 4 o frigorífico é indicado como um dos dispositivos que sofreu uma mudança de potência bastante elevada, provavelmente porque se encontrava numa das fases de refrigeração. Já na FSM 3 aquela pequena mudança de potência relacionada com o frigorífico pode dever-se a uma abertura da porta.

Porém, este algoritmo apresenta algumas falhas. Não disponibiliza gráficos, sendo estes muito importantes para visualizar de forma mais clara a inferência, uma vez que visualmente é possível averiguar determinadas falhas que a tabela de *clusters* e da máquina de estados finitos podem esconder. Também não apresenta nenhuma das métricas referidas no capítulo 2. Na tabela 5.2 são sugeridos dois dispositivos possíveis para eventos com aquela variação de potência, o que é pouco assertivo.

Tabela 5.2: Máquina de estados finitos

FSM	Δ Potência <i>Cluster</i> 1 (W)	Δ Potência <i>Cluster</i> 2 (W)	Dispositivo 1	Dispositivo 2
1	1860	−1855	Fogão	Fervedor
2	2447	−2438	Fogão	Laptop
3	13	−12	Laptop	Frigorífico
4	1128	−1097	Fogão	Frigorífico
5	85	−68	Congelador	Frigorífico

5.2 Algoritmo de Weiss

Weiss et al. (2012) criou um algoritmo que recorre a métodos de aprendizagem supervisionados, ou seja, após a extração dos eventos do consumo agregado o algoritmo atribui a cada evento o dispositivo que apresenta maior compatibilidade com os dados de cada dispositivo individual que existem na base de dados. As configurações que são necessárias definir para cada experiência são as seguintes: qual a base de dados, a casa ou conjuntos de casas, número de dias escolhido para a avaliação, quantas vezes se repete a inferência em intervalos de treino diferentes, número de dias escolhidos para treino, granularidade escolhida (em segundos) e neste algoritmo existe a possibilidade de recurso ao filtro média-mediana. O filtro mediana-média é utilizado para remover o ruído que pode existir no sinal. Como o próprio nome indica é a junção de dois filtros: filtro de mediana e filtro de média. Assim sendo, tendo uma dada vizinhança de um sinal, deve-se, primeiramente, seleccionar o valor

do sinal e dos seus vizinhos. Seguidamente, determina-se a mediana ordenando, por ordem crescente, os valores dos sinais vizinhos e alvo e substituindo o valor do sinal alvo pelo valor que se encontra no meio da ordenação. Por fim, atribui-se o valor da mediana ao equivalente da vizinhança de um sinal (o que permite a remoção de *outliers*). Após a aplicação do filtro anterior, é implementado o filtro de média, onde o valor de cada leitura é substituído pela média de todos os valores na sua vizinhança (suavizando o sinal).

Na realização das experiências com este algoritmo utilizou-se a casa 2 do conjunto de dados ECO. Dos 90 dias escolhidos, 15 dias foram para treino e 75 dias foram para teste. O dispositivo em análise é o frigorífico.

Como já foi referido, o algoritmo realiza uma comparação entre os eventos detetados no consumo agregado e as assinaturas de cada dispositivo. Devido à falta de assinaturas dos dispositivos, o algoritmo encontra-se modificado no *framework open source* utilizado, tendo um período de treino com os dados das *plugs*. Neste período de treino são obtidas as assinaturas. O algoritmo procura intervalos de tempo em que o dispositivo esta em utilização nos dados da *plug* e extraí o comportamento da carga. No final deste processo são obtidas as assinaturas que serão utilizadas na identificação dos dispositivos. Na figura 5.1 encontra-se representado a verde um dos dias correspondente ao consumo do frigorífico. A vermelho encontra-se o consumo inferido pelo algoritmo após a correspondência do consumo agregado com as assinaturas.




Figura 5.1: Weiss - Consumo real e consumo inferido

Após a deteção dos instantes temporais nas *plugs*, de onde se recolheram as assinaturas dos dados, inicia-se a deteção de eventos no consumo total. Na figura 5.2 encontra-se representado esse mesmo processo. Para cada evento ON detectado o al-

goritmo procura o evento OFF correspondente. A linha verde contínua representa a detecção de eventos ON e a linha verde descontinua corresponde aos eventos OFF. As linhas contínuas e descontinuas a cinzento referem-se aos eventos denominados falsos negativos, eventos ON não detetados. As linhas contínuas e descontinuas a vermelho representam eventos denominados falsos positivos, eventos OFF classificados como ON.




Figura 5.2: Weiss - Detecção dos eventos ON e OFF do frigorífico no consumo agregado.

Na tabela 5.3, estão representadas as assinaturas obtidas na experiência. A primeira coluna diz respeito ao nome do dispositivo, a segunda coluna representa a potência ativa (W) e por fim, a terceira tabela referente à potência reativa (VA). O frigorífico e o congelador são dois dispositivos que apresentam comportamentos semelhantes, têm um evento inicial e um evento de paragem, e o consumo ao longo desses movimentos é quase sempre constante. Observando a tabela 5.3 onde se encontram as assinaturas verificamos que existe uma diferença da potência ativa quando o dispositivo está a ser ligado de 16.76W e quando está a ser desligado de 18.28W.

Na tabela 5.4 estão detalhados os valores das métricas obtidas pelo Algoritmo de Weiss na inferência do frigorífico. Verifica-se que o frigorífico é inferido com uma precisão de 97.05%. Na figura 5.3 está representado o consumo inferido a vermelho e o consumo total a azul onde se observa que a inferência do frigorífico é quase certa, as falhas que se verificam no dia representado é nas alturas em que existe uma maior ativação dos dispositivos. O mesmo acontece nos restantes dias de avaliação, quando existem vários dispositivos ligados ao mesmo tempo o algoritmo apresenta

Tabela 5.3: Assinaturas obtidas para cada dispositivo da casa 2

Dispositivo	Δ Potência (W)	Δ Potência Reativa (VA)
Frigorífico	-69.00	-6.14
Frigorífico	80.02	4.13
Congelador	-50.72	16.58
Congelador	63.26	-19.75
Máquina de lavar loiça	-2064.74	-0.86
Máquina de lavar loiça	2062.24	-13.70
Fervedor	-1855.14	0.63
Fervedor	1866.91	-4.39
Fogão	-1174.38	-663.60
Fogão	-904.50	-519.02
Fogão	927.76	535.19
Fogão	1170.13	645.19
Lâmpada	-139.81	-167.93
Lâmpada	-203.77	-119.44
Lâmpada	208.08	70.86
Lâmpada	69.60	70.79
Laptop	-22.10	-5.00
Laptop	23.84	4.37
TV	-159.61	-34.80
TV	163.47	27.62
Stereo	-31.85	-29.59
Stereo	52.21	53.18
Stereo	160.86	24.36

mais dificuldades na detecção do frigorífico, uma vez que para detecção de eventos se torna mais complicada no consumo agregado.

5.3 Algoritmo de Parson

Como já foi explicado no capítulo 3, o modelo é semi-supervisionado, ou seja, recorre a informações gerais¹ sobre as características do dispositivo em análise. Neste caso específico o aparelho que vai ser inferido é o frigorífico. Parson et al. (2012) afirma que é a carga onde é mais fácil detetar um período no consumo agregado para treino,

¹Parson et al. (2012) utilizaram a base de dados *Tracebase* para estimar os parâmetros que definem o modelo com informação geral do dispositivo




Figura 5.3: Weiss - Visualização do consumo inferido no consumo agregado.

Tabela 5.4: Resultado das métricas na inferência do frigorífico recorrendo ao algoritmo de Weiss

Métrica	Valor
Fscore	0.9073
Precision	0.9705
Recall	0.8518
Desvio	0.0728
RMS	27.7417

pois é durante a madrugada, que este aparelho se destaca, uma vez que é quando se encontram menos dispositivos ativados. Neste caso, é nas configurações que se cria o modelo geral do dispositivo. É necessário definir o conjunto de dados, a casa ou conjuntos de casas, o número de dias escolhido para a avaliação, a granularidade, e o dispositivo, como nos outros todos. Contudo o que é diferente dos outros é a definição da média² e variância³ ON e OFF do dispositivos, assim como as probabilidades de transição de estado. Para este algoritmo ainda é necessário escolher qual o tipo de treino que se pretende treino com a *plug*, com o consumo agregado ou sem treino) e quantas horas tem a janela de treino. Este algoritmo vai ser validado em dois conjuntos de dados: REDD e ECO.

²média da distribuição de Gauss que descreve a mudança no consumo de energia

³variância da distribuição Gaussiana que descreve a mudança no consumo

5.3.1 Experiência com o conjunto de dados REDD

Para que a utilização da base de dados REDD fosse possível, foram efetuadas algumas adaptações. Primeiramente, pelo facto do *framework* NILM-EVAL apresentar uma estrutura específica para os dados (representada na figura 4.1), surgiu a necessidade de procurar saber qual o dia e a hora a que cada medição corresponde. Porém, o conjunto de dados não disponibiliza nenhuma das informações diretamente, apenas fornece o *Unix epoch*⁴. Esta é uma maneira de controlar o tempo total em segundos, ou seja, o *Unix epoch* é apenas o número de segundos entre o *Unix epoch* e uma determinada data. Após a conversão para UTC ainda se teve de ajustar a hora tendo em conta o fuso horário de Massachusetts (UTC/GMT -4). Seguidamente, como o *framework* foi realizado para dados cujas medições são de segundo a segundo, os dados REDD tiveram que ser ajustados. Como já foi referido no capítulo anterior, os dados das *plugs* apresentam variações na amostragem dos valores de potência (há valores sucessivos reportados com 3s de diferença como 4s e outros valores). Dados estes desfasamentos foi necessário homogeneizar a amostra a analisar. Em relação aos dados do consumo agregado, apesar de maior parte dos dados se encontrarem registados de segundo a segundo, também se verificam algumas falhas de registo. Para fazer face a esta limitação, inicialmente, pensou-se em substituir os valores em falta por zero, contudo, iria induzir em erro no cálculo das métricas e até mesmo a própria inferência, uma vez que na fase de treino iria existir valores médios incorretos. Assim sendo, a melhor solução encontrada foi a criação de um *script* em *R* capaz de replicar um valor médio (fazendo a média das duas ultimas medições). Construindo assim, um novo conjunto de dados a partir do conjunto discreto de dados pontuais previamente conhecidos. Assim sendo, no final são esperadas 86400 medições por dia ($24h \times 60min \times 60seg$).

Apesar de existirem 6 casas, apenas foram utilizadas as casas: nº1 e a nº2, uma vez que, eram as únicas com o maior número de registos de dias consecutivos do consumo individual do dispositivo e do consumo agregado em dias consecutivos.


O gráfico no anexo A ilustra as diferenças de potência que existem entre os dois frigoríficos, é possível concluir que o frigorífico utilizado na casa 1 apresenta uma potência mais elevada do que o dispositivo da casa 2. Existem diversos fatores que podem justificar esta diferença: serem de marcas diferentes, apresentarem potências de consumo ligeiramente diferentes, condições de operação, idade, entre outras. Comparando também com o conjunto de dados ECO (que é europeu) verifica-se um desfasamento entre a potência ON da casa desse mesmo conjunto de dados e a potência ON das outras duas casas que pertencem à base de dados REDD. Uma possível explicação será que os modelos utilizados no mercado Americano são diferentes dos utilizados na Europa.

⁴A primeira contagem iniciou-se a 1 de janeiro de 1970 em UTC

Casa nº1

Da casa número 1 foi possível extrair 13 dias consecutivos de dados, entre 2011-04-19 e 2011-05-01. Todavia, nos dias 2011-04-28 e 2011-04-29 apenas se verificavam 20% e 7% das medições necessárias, em contraste com os restantes dias onde as medições rondam os 99%. Optamos então, por omitir estes dois dias pois iriam induzir em erro os resultados.

Figura 5.4: Resultado da experiência com as médias do *tracebase*, consumo inferido (vermelho) e consumo da *plug* (verde)



No total foram utilizados 11 dias, 5 dias para treino e 6 dias para teste. A granularidade fixada foi de 60 segundos, não foi utilizado nenhum filtro e o dispositivo escolhido para ser inferido foi o frigorífico. Os valores originais da média ON e OFF, como já foi referido, foram obtidos com recurso ao conjunto de dados *tracebase*, e eram respetivamente, 60W para a média ON e 2W para a média OFF. Testando o algoritmo com esses valores pré definidos, representado na figura 5.4, observa-se um desvio significativo entre a média ON inferida e a potência ON do dispositivo. Os valores pré-definidos são demasiado baixos para o conjunto de dados em utilização, necessitam de ser ajustados.

Decidiu-se recorrer à teoria de Parson et al. (2012), observaram-se períodos de tempo em que apenas o frigorífico se encontrava ativado, e mediu-se a potência ON e OFF nesses instantes e fez-se uma média. A média ON obtida foi de 180W e a média OFF 7W. Em relação aos restantes valores, esses mantiveram-se inalteradas. Consideraram-se diferentes tamanhos para a janela de treino a fim de avaliar o seu impacto na qualidade da inferência feita pelo algoritmo. Num caso optou-se por utilizar janela de treino com 3 horas e no outro 5 horas. O tipo de treino utilizado foi com recurso ao consumo agregado.

O gráfico ilustrado na figura 5.5 representa a verde a leitura da *plug* do dispositivo




Figura 5.5: Parson REDD casa 1 - Comparação entre o consumo inferido e o consumo real da experiência com uma janela de treino de 3 horas.

(medição real) e a vermelho está representada a medição estimada pelo algoritmo através do consumo agregado no dia 30 de Abril de 2011. É possível observar que existem várias correspondências. Contudo, o algoritmo apresenta uma melhor performance quando se aumenta a janela de treino para 5 horas, como se pode ver nas figuras 5.5 e 5.6. Aumentando o número de horas na janela de treino aumenta a precisão da inferência. Isto acontece porque como são apenas utilizados para treino 5 dias um aumento neste parâmetro leva a uma maior eficácia no treino. Porém, o




Figura 5.6: Parson REDD casa 1 - Comparação entre o consumo inferido e o consumo real da experiência com uma janela de treino de cinco horas.

número de janela não deverá ser aumentado sob pena de se ter overfitting de treino em relação a uma amostra e consequentemente desvios grandes na inferência para outras amostras. Em anexo B é possível ver gráficos com a comparação do consumo inferido com o consumo total e do consumo real com o consumo total, nas diferentes experiências.

Como já era de esperar, existe uma correspondência perfeita entre o consumo real e o consumo total, representado nas figuras B.2 e B.4. Focando no comportamento do consumo total, entre o meio dia e as três da tarde, observa-se o acionamento de outras cargas com uma potência bastante elevada, o que é normal, uma vez que se trata da hora em que os habitantes almoçam. Na tabela 5.5 encontram-se os resultados da desagregação. Conclui-se que com o aumento do número de horas da janela de treino a inferência apresenta maior precisão, a proporção do desvio do consumo de energia estimado do consumo de energia real ao longo de um período de tempo diminui e o RMS também diminui.

Tabela 5.5: Resultado das métricas da primeira casa

Métrica	Valor com 3 horas	Valor com 5 horas
Fscore	0.4459	0.6089
Precision	0.8564	0.9129
Recall	0.3014	0.4568
Desvio	0.6360	0.5184
RMS	84.7482	75.2931

Após os resultados obtidos na experiência anterior surgiu a ideia de testar como o algoritmo reagiria se tivesse com um fim-de-semana para treino e com outro fim-de-semana para teste, usando uma média ON de 180W e uma média OFF de 7W. Uma vez que apenas existem dois dias de treino, foram testadas janelas de treino com tamanhos diferentes de modo a obter a melhor solução. Assim sendo, escolheram-se 3 janelas de treino, uma vez que se obtiveram melhores resultados. Com esta experiência é evidente a melhoria na inferência com dados do fim-de-semana, uma vez que se estão a treinar dois conjuntos de dias iguais, onde se assume que comportamento elétrico é idêntico, já que o perfil de uso dos dispositivos na casa será similar.

Casa nº2

No total, para esta habitação foram retirados dados de duas semanas, tendo sido escolhida uma semana (6 dias) para treino e outra para teste. No total para a casa número dois dispomos de 12 dias (de 2011-04-19 e 2011-04-30). A granularidade imposta foi de 60 segundos, não foi utilizado nenhum filtro e o dispositivo a ser inferido foi o frigorífico.




Figura 5.7: Parson REDD casa 1 - Comparação entre o consumo inferido e o consumo real da experiência com um fim-de-semana como período de treino e teste.

Tabela 5.6: Resultado das métricas com treino no fim de semana

Métrica	Valor
Fscore	0.6802
Precision	0.8696
Recall	0.5585
Desvio	0.3937
RMS	72.0296

Tal como para a casa número um, na casa número 2 os valores originais da média ON e OFF não se aplicam. Recorreu-se ao mesmo método que na casa 1 e os resultados foram: 163W para a média ON e 6W para a média OFF. Os restantes valores mantiveram-se com as configurações pré-definidas. Os gráficos que se seguem foram realizados com as médias enunciadas anteriormente.

No gráfico 5.8 é possível observar que as correspondências entre o real e o estimado (no dia em análise) são quase totais.

Na tabela 5.7 encontram-se registados os resultados obtidos. A inferência para esta casa obteve uma precisão de 97%.

5.3.2 Experiência com o conjunto de dados ECO

De forma a se poder verificar o comportamento do algoritmo numa base de dados diferente foi realizado um novo teste, agora utilizando-se um conjunto de dados europeu.

Tabela 5.7: Resultado das métricas da segunda casa

Métrica	Valor
Fscore	0.7201
Precision	0.9756
Recall	0.5707
Desvio	0.2480
RMS	81.3646

Assim, das seis casas existentes neste conjunto foi escolhida a primeira casa para a realização deste novo teste. O número de dias utilizado para avaliação foi de 90 dias onde 80 foram para a avaliação e apenas 10 destes dias foram para o treino. Em relação à definição dos parâmetros do modelo geral do dispositivo, estes permaneceram inalterados (valores, média, variância ON/OFF e probabilidade de transição de estado) continuando o número de horas da janela de treino foi de 3 horas. Analisando os resultados obtidos por este algoritmo verificou-se a existência de uma falha significativa na deteção do dispositivo. O comportamento do consumo inferido aparenta ser uma deteção de eventos, como se pode confirmar na figura 5.9, não representando o consumo da carga. Os resultados obtidos pelo algoritmo são piores para a deteção do frigorífico pese embora o facto de o perfil de uso do dispositivo ser nada mais evidente durante a madrugada, onde tal como nos outros casos não existem outros dispositivos em operação.

Numa tentativa de descobrir qual poderia ser o problema, examinaram-se os




Figura 5.8: Parson REDD casa 2 - Comparação entre o consumo inferido e o consumo real.

gráficos do consumo agregado para ver qual era o padrão do consumo total nas horas em que a ativação deveria ser predominantemente do frigorífico, representado no anexo C. O que se verificou é que nesse mesmo instante existe uma outra carga, com um comportamento muito similar ao do frigorífico em funcionamento, o congelador. Observando, em anexo D, é notória a semelhança entre os aparelhos.

Para minimizar o impacto deste segundo dispositivo na inferência do primeiro, decidiu-se testar como é que o algoritmo se comportaria caso o sinal do congelador fosse removido do consumo agregado. Portanto, aos 90 dias de consumo agregado subtraíram-se os 90 dias correspondentes ao consumo do congelador. Comparando os gráficos das figuras 5.9 e 5.10 (consumo agregado antes e depois de retirar a carga) verifica-se uma diferença, sendo que no gráfico 5.11 já é perceptível a ativação e desativação do frigorífico nas horas da madrugada. Mas mesmo assim a inferência ainda apresenta muitas dificuldades na deteção da carga.

Realizou-se assim uma nova experiência onde se optou, primeiramente, por utilizar um filtro passa baixo, que permite a passagem de baixas frequências e atenua as que apresentam uma amplitude superior à frequência de corte. Foi aplicado no consumo agregado, no consumo individual do frigorífico e do congelador. O filtro foi utilizado nestes três consumos porque no consumo individual de cada dispositivo existem picos muito elevados (referentes ao momento de refrigeração de ambos) que ao serem amenizados tornam mais claro o desempenho dos aparelhos. A sua ação no consumo agregado serve para eliminar algum tipo de ruído que possa existir, e uma vez que foi aplicado nos consumos individuais faz sentido que se aplique no consumo total para obter uma deteção homogênea. Posteriormente, subtraiu-se o valor do consumo do congelador filtrado ao consumo agregado filtrado.




Figura 5.9: Parson eco experiência 1 - Comparação entre o consumo real e o consumo inferido, utilizando os dados sem nenhuma alteração.




Figura 5.10: Parson ECO experiência 2 - Comparação entre o consumo real e o consumo inferido, utilizando os dados do consumo total sem o consumo do congelador.




Figura 5.11: Parson ECO experiência 2 - Comparação entre o consumo inferido e o consumo total, utilizando os dados do consumo total sem o consumo do congelador.

É notória a evolução na inferência do frigorífico ao longo das três experiências. O consumo inferido apresenta um comportamento parecido com a carga e deteta com maior eficácia o padrão do dispositivo, como se pode ver no anexo E. Na tabela 5.8 encontram-se os resultados da desagregação. Conclui-se que com as alterações efetuadas no conjunto de dados inferência apresenta maior precisão, a proporção do desvio do consumo de energia estimado do consumo de energia real ao longo de um período de tempo diminui, assim como, o RMS também diminui.




Figura 5.12: Parson ECO experiência 3 - Comparação entre o consumo real e o consumo inferido, utilizando os dados do consumo total sem o consumo do congelador e com a aplicação de um filtro passa baixo.

Tabela 5.8: Resultado das métricas com os dados ECO

Métrica	Experiência 1	Experiência 2	Experiência 3
Fscore	0.4114	0.3700	0.5898
Precision	0.4570	0.5098	0.6431
Recall	0.3741	0.2904	0.5446
Desvio	0.2801	0.2201	0.0103
RMS	31.6920	29.6418	27.1063

Capítulo 6

Conclusões

Com o intuito de perceber como se procede a desagregação de cargas, por métodos não intrusivos, foram analisados e validados três algoritmos distintos. Em relação ao algoritmo de Baranski, conclui-se que este fornece informação sobre todos os dispositivos presentes na casa, não se focando em um único apenas. Não necessita de qualquer tipo de informação inicial sobre as cargas individualmente. Tendo o consumo agregado este consegue proceder à desagregação. Porém, a inferência fornecida pelo algoritmo não é de todo concreta. Obtemos informação sobre quais os dois dispositivos com maior proporção de eventos associados a uma determinada variação de potencia. Este tipo de informação pode ser útil em trabalhos futuros.

O algoritmo de Weiss difere completamente do algoritmo anterior. Para o seu funcionamento, é fundamental, ter informação inicial sobre o dispositivo a ser inferido. O que é uma limitação, porque para se ter acesso a esse tipo de dados é necessário recorrer a *plugs*, o que é muito dispendioso. Apesar disso, devido ao seu processo de deteção é o algoritmo que obtém maior precisão na desagregação de cargas, após ter sido testado com o conjunto de dados ECO. Já era previsível que tal acontecesse, uma vez que, tendo como processo de treino, a deteção dos intervalos de tempo na *plug* em que foi ativado e desativado, para posteriormente utilizar no consumo agregado, era muito difícil existirem falhas significativas, sem ser nos momentos em que se encontram vários dispositivos ligados, pois aí a deteção é mais complicada.

Em relação ao algoritmo de Parson, este apresenta um método de deteção bastante curioso. Oficialmente, a teoria não necessita de qualquer tipo de dados sobre o consumo individual do dispositivo. O que é realmente necessário saber, é um modelo geral de cada dispositivo, mais concretamente a média e a variância de quando o dispositivo se encontra ativado e desativado e as probabilidades de transição de estado (ON para OFF e OFF para ON). Este é a chave do algoritmo de Parson e o elemento que o diferencia de todos os outros. Não sendo necessário dados do consumo real do dispositivo, torna-se num método de deteção bastante barato, comparando com o método anterior. A abordagem foi testada em duas bases de dados distintas, REDD

e ECO. Foram necessárias algumas alterações às mesmas, em relação ao primeiro conjunto de dados, primeiro foram convertidas as medições que se encontravam em EPOCH para UTC e teve de ajustar a hora o fuso horário em Massachusetts (USA). Seguidamente, dado que os dados apresentavam várias falhas nas medições, criou-se em *script* em R capaz de replicar (uma média) das medições em falta. Depois destas alterações foi possível realizar testes nas casas 1 e 2 (estas foram escolhidas por apresentarem o maior numero de dias com medições consecutivas) para inferir o frigorífico. Para a casa número 1 realizaram-se três experiências. A primeira e a segunda englobavam o mesmo modelo geral do dispositivo. A única diferença entre os dois testes foi o número de janelas de treino escolhidas. Obteve-se melhores resultados na experiência com 5 janelas de treino, o que já era espectável, devido ao número de dados reduzidos com um aumento das janelas de treino iria aumentar a precisão na inferência. No terceiro teste, em vez de cinco dias de treino, optou-se por escolher um fim-de-semana para treino e outro para teste. Obteve uma precisão de 86%, o que é normal, pois estão se a testar dias comparáveis por serem ambos fim-de-semana. No que toca à base de dados ECO, como a casa escolhida (a número 2) apresentava uma carga acionada em simultâneo, o frigorífico, existiu necessidade de eliminar a mesma e utilizar um filtro passa baixo para atenuar o sinal. É possível verificar, tanto pelos gráficos como pela tabela onde se encontram as métricas, que ao longo dos testes realizados com este conjunto de dados, existe uma melhoria contínua na inferência. Através desta ultima experiência, encontrou-se uma limitação do algoritmo, quando existe uma carga com um comportamento similar, o modelo apresenta dificuldades em inferir o consumo.

Ao longo desta tese também foi possível concluir que a fase de recolha de dados e de tratamento dos mesmos é muito importante para conseguir uma desagregação eficaz. Dados que apresentam com desfasamentos irreais e medições com demasiado ruído não permitem obter os resultados confiáveis.

6.1 Trabalho Futuro

Como propostas de trabalhos futuros, são sugeridos os seguintes tópicos:

- Investir em técnicas de pré-tratamento dos dados de forma a permitir uma maior qualidade da análise e estimação dos algoritmos de desagregação;
- Utilizar o algoritmo de Parson para desagregar outros dispositivos tendo em conta os padrões que vão sobressaindo.
- Tendo um número reduzido de aparelhos de medição (limitado, as 3 *plugs*), quais seriam os dispositivos escolhidos para serem medidos pelas mesmas, de modo a obter a máxima precisão na desagregação.

Bibliografia

- Anderson, K., A. Ocneanu, D. Benitez, D. Carlson, A. Rowe, and M. Berges (2012). Blued: A fully labeled public dataset for event-based non-intrusive load monitoring research. In *Proceedings of the 2nd KDD workshop on data mining applications in sustainability (SustKDD)*, pp. 1–5.
- Baranski, M. and J. Voss (2003). Nonintrusive appliance load monitoring based on an optical sensor. In *Power Tech Conference Proceedings, 2003 IEEE Bologna*, Volume 4, pp. 8–pp. IEEE.
- Baranski, M. and J. Voss (2004a). Detecting patterns of appliances from total load data using a dynamic programming approach. In *Data Mining, 2004. ICDM'04. Fourth IEEE International Conference on*, pp. 327–330. IEEE.
- Baranski, M. and J. Voss (2004b). Genetic algorithm for pattern detection in nialm systems. In *Systems, Man and Cybernetics, 2004 IEEE International Conference on*, Volume 4, pp. 3462–3468. IEEE.
- Barker, S., A. Mishra, D. Irwin, E. Cecchet, P. Shenoy, and J. Albrecht (2012). Smart*: An open data set and tools for enabling research in sustainable homes. *SustKDD, August 111*, 112.
- Batra, N., J. Kelly, O. Parson, H. Dutta, W. Knottenbelt, A. Rogers, A. Singh, and M. Srivastava (2014). Nilmtk: an open source toolkit for non-intrusive load monitoring. In *Proceedings of the 5th international conference on Future energy systems*, pp. 265–276. ACM.
- Beckel, C. (2015). *Scalable and Personalized Energy Efficiency Services with Smart Meter Data*. Ph. D. thesis, ETH Zurich, Zurich, Switzerland.
- Beckel, C., W. Kleiminger, R. Cicchetti, T. Staake, and S. Santini (2014, November). The eco data set and the performance of non-intrusive load monitoring algorithms. In *Proceedings of the 1st ACM International Conference on Embedded Systems for Energy-Efficient Buildings (BuildSys 2014). Memphis, TN, USA*, pp. 80–89. ACM.

- Berges, M., E. Goldman, H. S. Matthews, and L. Soibelman (2009). Learning systems for electric consumption of buildings. In *ASCI international workshop on computing in civil engineering*, Volume 38.
- Berges, M. E., E. Goldman, H. S. Matthews, and L. Soibelman (2010). Enhancing electricity audits in residential buildings with nonintrusive load monitoring. *Journal of industrial ecology* 14(5), 844–858.
- Bijker, A. J., X. Xia, and J. Zhang (2009). Active power residential non-intrusive appliance load monitoring system. In *AFRICON, 2009. AFRICON'09.*, pp. 1–6. IEEE.
- Cole, A., A. Albicki, et al. (1998a). Algorithm for nonintrusive identification of residential appliances. In *Circuits and Systems, 1998. ISCAS'98. Proceedings of the 1998 IEEE International Symposium on*, Volume 3, pp. 338–341. IEEE.
- Cole, A., A. Albicki, et al. (1998b). Data extraction for effective non-intrusive identification of residential power loads. In *Instrumentation and Measurement Technology Conference, 1998. IMTC/98. Conference Proceedings. IEEE*, Volume 2, pp. 812–815. IEEE.
- Farinaccio, L. and R. Zmeureanu (1999). Using a pattern recognition approach to disaggregate the total electricity consumption in a house into the major end-uses. *Energy and Buildings* 30(3), 245–259.
- Figueiredo, M. (2014). Contributions to electrical energy disaggregation in a smart home. *Faculdade de Engenharia da Universidade de Coimbra*.
- Figueiredo, M., A. d. Almeida, and B. Ribeiro (2012). Home electrical signal disaggregation for non-intrusive load monitoring (nilm) systems. *ELSEVIER*, 66–73.
- Figueiredo, M. B., A. de Almeida, and B. Ribeiro (2011). An experimental study on electrical signature identification of non-intrusive load monitoring (nilm) systems. In *Proceedings of the 10th International Conference on Adaptive and Natural Computing Algorithms - Volume Part II, ICANNGA'11*, Berlin, Heidelberg, pp. 31–40. Springer-Verlag.
- Goncalves, H., A. Ocneanu, M. Berges, and R. Fan (2011). Unsupervised disaggregation of appliances using aggregated consumption data. In *The 1st KDD Workshop on Data Mining Applications in Sustainability (SustKDD)*.
- Hart, G. W. (1992). Nonintrusive appliance load monitoring. *Proceedings of the IEEE* 80(12), 1870–1891.
- Jean-Paul Zimmermann, Matt Evans, J. G. N. K. L. H. P. R. and C. Evans. Household electricity survey a study of domestic electrical product usage.

- Kolter, J. Z. and T. Jaakkola (2012). Approximate inference in additive factorial hmms with application to energy disaggregation. In N. D. Lawrence and M. A. Girolami (Eds.), *Proceedings of the Fifteenth International Conference on Artificial Intelligence and Statistics (AISTATS-12)*, Volume 22, pp. 1472–1482.
- Kolter, J. Z. and M. J. Johnson (2011a). Redd: A public data set for energy disaggregation research. In *in SustKDD*.
- Kolter, J. Z. and M. J. Johnson (2011b). Redd: A public data set for energy disaggregation research. In *Workshop on Data Mining Applications in Sustainability (SIGKDD)*, San Diego, CA, Volume 25, pp. 59–62. Citeseer.
- Lai, Y.-X., C.-F. Lai, Y.-M. Huang, and H.-C. Chao (2013, May). Multi-appliance recognition system with hybrid svm/gmm classifier in ubiquitous smart home. *Inf. Sci.* 230, 39–55.
- Laughman, C., K. Lee, R. Cox, S. Shaw, S. Leeb, L. Norford, and P. Armstrong (2003). Power signature analysis. *Power and Energy Magazine, IEEE* 1(2), 56–63.
- Liang, J., S. K. Ng, G. Kendall, and J. W. Cheng (2010). Load signature study part i: Basic concept, structure, and methodology. *Power Delivery, IEEE Transactions on* 25(2), 551–560.
- Lichman, M. (2013). UCI machine learning repository.
- Maasoumy, M., B. Sanandaji, K. Poolla, and A. S. Vincentelli (2013). Berds-berkeley energy disaggregation data set. In *Proceedings of the Workshop on Big Learning at the Conference on Neural Information Processing Systems (NIPS)*.
- Makonin, S., F. Popowich, L. Bartram, B. Gill, and I. V. BajiÄ (2013, Aug). Ampds: A public dataset for load disaggregation and eco-feedback research. In *Electrical Power Energy Conference (EPEC), 2013 IEEE*, pp. 1–6.
- Marceau, M. and R. Zmeureanu (2000). Nonintrusive load disaggregation computer program to estimate the energy consumption of major end uses in residential buildings. *Energy Conversion and Management* 41(13), 1389 – 1403.
- Monacchi, A., D. Egarter, W. Elmenreich, S. D’Alessandro, and A. M. Tonello (2014). Greend: An energy consumption dataset of households in italy and austria. In *Smart Grid Communications (SmartGridComm), 2014 IEEE International Conference on*, pp. 511–516. IEEE.
- Murray, D., J. Liao, L. Stankovic, V. Stankovic, R. Hauxwell-Baldwin, C. Wilson, M. Coleman, T. Kane, and S. Firth (2015). *A data management platform for personalised real-time energy feedback*.

- Parson, O. (2011). Using hidden markov models for non-intrusive appliance load monitoring. Technical report, tech. rep., University of Southampton.
- Parson, O. (2014). *Unsupervised training methods for non-intrusive appliance load monitoring from smart meter data*. Ph. D. thesis, University of Southampton.
- Parson, O., S. Ghosh, M. Weal, and A. Rogers (2012). Non-intrusive load monitoring using prior models of general appliance types.
- Patel, S. N., T. Robertson, J. A. Kientz, M. S. Reynolds, and G. D. Abowd (2007). At the flick of a switch: Detecting and classifying unique electrical events on the residential power line. In *Proceedings of the 9th International Conference on Ubiquitous Computing*, UbiComp '07, Berlin, Heidelberg, pp. 271–288. Springer-Verlag.
- Powers, J., B. Margossian, and B. Smith (1991). Using a rule-based algorithm to disaggregate end-use load profiles from premise-level data. *Computer Applications in Power, IEEE* 4(2), 42–47.
- Reinhardt, A., P. Baumann, D. Burgstahler, M. Hollick, H. Chonov, M. Werner, and R. Steinmetz (2012). On the Accuracy of Appliance Identification Based on Distributed Load Metering Data. In *Proceedings of the 2nd IFIP Conference on Sustainable Internet and ICT for Sustainability (SustainIT)*, pp. 1–9.
- Shaw, S. R., S. B. Leeb, L. K. Norford, and R. W. Cox (2008). Nonintrusive load monitoring and diagnostics in power systems. *IEEE Transactions on Instrumentation and Measurement* 57(7), 1445–1454.
- Srinivasan, D., W. Ng, and A. Liew (2006). Neural-network-based signature recognition for harmonic source identification. *Power Delivery, IEEE Transactions on* 21(1), 398–405.
- Uttama Nambi, A. S., A. Reyes Lua, and V. R. Prasad (2015). Loded: Location-aware energy disaggregation framework. In *Proceedings of the 2Nd ACM International Conference on Embedded Systems for Energy-Efficient Built Environments*, BuildSys '15, New York, NY, USA, pp. 45–54. ACM.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. New York, NY, USA: Springer-Verlag New York, Inc.
- Weiss, M., A. Helfenstein, F. Mattern, and T. Staake (2012, March). Leveraging smart meter data to recognize home appliances. In *Pervasive Computing and Communications (PerCom), 2012 IEEE International Conference on*, pp. 190–197.

Zeifman, M. and K. Roth (2011). Nonintrusive appliance load monitoring: Review and outlook. *IEEE Transactions on Consumer Electronics*, 76–84.

Anexo A




Figura A.1: Consumo elétrico do frigorífico na casa 1 (azul) e na casa 2 (vermelho) da base de dados REDD e o consumo do frigorífico da casa 2 (verde) da base de dados ECO

Anexo B




Figura B.1: Parson REDD casa 1 - Comparação entre o consumo inferido e consumo agregado, da experiência com três janelas de treino.




Figura B.2: Parson REDD casa 1 - Comparação entre o consumo real e consumo agregado, da experiência com três janelas de treino.




Figura B.3: Parson REDD casa 1 - Comparação entre o consumo inferido e consumo agregado, da experiência com cinco janelas de treino.




Figura B.4: Parson REDD casa 1 - Comparação entre o consumo real e consumo agregado, da experiência com cinco janelas de treino.

Anexo C




Figura C.1: Parson ECO - Comparação entre o consumo inferido e o consumo total. Verifica-se que o comportamento durante a madrugada não apresenta um padrão que permita identificar o Frigorífico.

Anexo D




Figura D.1: Parson ECO - Comparação entre o consumo do frigorífico e do congelador

Anexo E




Figura E.1: Parson ECO experiência 3- Comparação entre o consumo do inferido e o consumo total.




Figura E.2: Parson ECO experiência 3- Comparação entre o consumo real e o consumo total.